

**Nurmikasvustojen havainnointi miehittämättömään ilma-
alukseen kiinnitettävällä multispektrikameralla**

Juho Kotala
Maisterintutkielma
Helsingin yliopisto
Maataloustieteiden osasto
Agroteknologia
2019

Tiedekunta/Osasto — Fakultet/Sektion — Faculty Maatalous-metsätieteellinen tiedekunta		Laitos — Institution — Department Maataloustieteiden osasto	
Tekijä — Författare — Author Juho Kotala			
Työn nimi — Arbetets titel — Title Nurmikasvustojen havainnointi miehittämättömään ilma-alukseen kiinnitettävällä multispektrikameralla			
Oppiaine — Läroämne — Subject Agroteknologia			
Työn laji — Arbetets art — Level Maisterintutkielma		Aika — Datum — Month and year 4/2019	Sivumäärä — Sidoantal — Number of pages 103
<p>Tiivistelmä — Referat — Abstract</p> <p>Kiinnostus dronen (myös nimitystä pienoiskopteri tai drooni käytetään) käyttöön kasvustojen tarkkailussa on lisääntynyt niiden yleistessä maataloilla viime vuosina. Kiinnostuksen kasvua ovat vauhdittaneet kuluttajaystävällinen hinta, laitteiden monipuoliset käyttömahdollisuudet eri oloissa sekä laitteiden helppokäyttöisyys.</p> <p>Tämän tutkimuksen tavoitteena oli kartoittaa droneen kiinnitettävän multispektrikameran käyttö/hyödyntämismahdollisuuksia suomalaisissa oloissa, joista tutkittua tietoa on toistaiseksi melko vähän saatavilla. Tavoitteena oli lisäksi tutkia voiko lähi-infrapunakarttaa ja normalisoitua kasvillisuusindeksikarttaa (NDVI -kartta) käyttää nurmen biomassakarttana; selvittää dronen soveltuvuutta lisähavainnointivälineeksi kasvustokäynnin yhteydessä. Tiedon hankintaa varten aineistoa kerättiin peltomittakaavassa Viikin opetus- ja tutkimustilan Koirasuon koelohkolta sekä Töysästä Isokytö -nimiseltä lohkolta.</p> <p>Drone-multispektrikamerajärjestelmällä kuvattujen karttojen tutkimiseksi koelohkolta kerättiin referenssinäytteitä kasvukauden aikana ennen ensimmäistä ja toista säilörehun korjuuta ja tehtiin mittauksia seuraavasti: otettiin nurmen korjuuaikana näyte, mitattiin kasvuston pituus, lehtialaindeksi ja lehtivihreän määrä sekä tehtiin kasvustohavainnoja ja yleishavainnoja lohkon eri osista. Tuloksia vertailtiin lohkolta kerättyihin biomassahavainnoihin.</p> <p>Kesän aikana Downwelling Light Sensor (DLS) eli kameran kirkkauden automaattinen säätövalosensori aiheutti tuloksiin merkittäviä virheitä. Yli puolet kuvatuista aineistosta oli käyttökelvotonta. Käyttökelvottomissa kuvissa kuvien pikselien heijastusarvo ei vastannut todellista. Ongelmaan löydettiin kuitenkin ratkaisu ja kuvaukset voitiin suorittaa loppuun.</p> <p>Yhdistettyjen tulosten perusteella lähi-infrapunakarttaa ($R^2= 55$), ja NDVI -karttaa ($R^2= 22$), voidaan käyttää biomassan määrän karkeaan arviointiin nurmiseoskasvustossa. Kuvien avulla voidaan tunnistaa ongelmakohtien esim. heikommin kasvavien alueiden laajuus. Täten kuvien havaintojen tekeminen ja mahdolliset mittaukset voidaan kohdentaa sijainteihin, joissa on tarve saada tarkempaa tietoa, miksi kasvusto on kasvanut lohkon muuta kasvustoa heikommin.</p> <p>Saman heijastuksen kasvustosta voi aiheuttaa useampi tekijä mm. paljas maanpinta tai tiheä kasvusto. Pelkän kartan perusteella ilman referenssiaineistoa kasvustokarttoja on vaikea hyödyntää täydessä laajuudessa. Tulosten perusteella lehtivihreähavainnot vaihtelivat satunnaisesti nurmiseoskasvustossa. Yksittäisiä nurmikasveja ei pystytty tunnistamaan kuvista, mutta useimpia samaa lajiketta kasvatat alueet kuten juolavehnäpesäkkeet pystyttiin tunnistamaan.</p> <p>Karttojen perusteella voidaan selittää maankäytön historiaa, havaita putkitettujen ojen/salaojen paikat. Sen sijaan yksittäisiä rikkakasveja on haastava tunnistaa, sillä kasvuston heijastus riippuu useista eri tekijäjäistä ja saman pikselin alueella voi mahtua sekä rikkakasvi että nurmikasvi. Kameran pikselikoko on riippuvainen lentokorkeudesta ja mitä likempää maanpintaa lennetään, sitä pienempi on pikselikoko. Tässä työssä käytettiin 50 m lentokorkeutta, jolloin spatiaalinen resoluutio oli 3,3 cm.</p>			
Avainsanat — Nyckelord — Keywords Kasvustokuvaus, biomassan määrittäminen, drone, multispektrikamera, täsmäviljely			
Säilytyspaikka — Förvaringsställe — Where deposited Maataloustieteiden laitos ja Viikin kampuskirjasto			
Muuta tietoa — Övriga uppgifter — Further information Työt ohjasivat Mikko Hakojärvi ja Laura Alakukku			

HELSINGIN YLIOPISTO — HELSINGFORS UNIVERSITET — UNIVERSITY OF HELSINKI

Tiedekunta/Osasto — Fakultet/Sektion — Faculty Faculty of Agriculture and Forestry		Laitos — Institution — Department Department of Agricultural Sciences
Tekijä — Författare — Author Juho Kotala		
Työn nimi — Arbetets titel — Title Grass field monitoring by using UAV and multispetra camera		
Oppiaine — Läroämne — Subject Agrotechnology		
Työn laji — Arbetets art — Level Master's thesis	Aika — Datum — Month and year 4/2019	Sivumäärä — Sidoantal — Number of pages 103
<p>Tiivistelmä — Referat — Abstract</p> <p>The interest to use drones in agricultural field monitoring is increasing because drones have become more popular during last few years. This is due to the affordable price of them, multi-function features in different conditions, and easy usability.</p> <p>The aim of this study was to explore the use/utilization of drone-multispectral camera system in Finnish field crop production. The aim was also to study if near-infrared map and normalized difference index (NDVI) can be used as a biomass map of grass and is it possible to identify how useful drones are as a supplementary visual aid in field inspection of the crop. Field tests were conducted on the Koirasuo field plot of the Viikki research farm and on the Isokytö field plot in Töysä in Southern Ostrobothnia.</p> <p>The test fields were mapped with drone-multispectral camera system. Reference samples crop were collected and field measurements were made based on these maps. The reference samples and field measurements made were: harvesting time sample, measurement of crop length, leaf area index and chlorophyll content. General crop and plot observations were made also. These results were compared with biomass samples.</p> <p>During the data collection period the Downwelling Light Sensor (DLS) i.e. the camera's auto-adjusting brightness sensor, caused significant distortions in the maps. More than half of material was useless for in this study for this reason. Useless pictures reflection value was different than normal conditions. However, a solution was found, and photoshooting could be completed.</p> <p>Based on the all results near-infrared maps ($R^2= 55$) and NDVI index ($R^2= 22$) can be used to do only rough biomass estimates on the grass field. Maps can be used also to identify low biomass areas on the field and to define the locations where more measurements or observations are needed.</p> <p>The same reflection from the crop can results from several factors, such as bare ground and dense vegetation. Without reference material, vegetation maps are difficult to analyse. Based on the results, chlorophyll content varies irregularly in different areas mixed grass corp.</p> <p>Maps can be used to explain the history of land use, to detect the locations on piped ditches/sup surfaces drains. Instead it is challenging to identify individual weeds because crop pixel reflection value depends several factors and weeds and crop can be in same pixel area. Pixel accuracy depend flight height and camera resolution. This thesis used 50 meter flight height and spatial resolution was 3,3 cm.</p>		
Avainsanat — Nyckelord — Keywords UAV aerial imagery, biomass estimation, drone, multispectral camera, precision agriculture		
Säilytyspaikka — Förvaringsställe — Where deposited Department of Agricultural Sciences and Viikki Campus Library		
Muita tietoja — Övriga uppgifter — Further information Supervisors were Mikko Hakojärvi and Laura Alakukku		

SISÄLLYS

LYHENTEET JA SYMBOLIT.....	6
1. JOHDANTO.....	8
2. KATSAUS KIRJALLISUUTEEN	10
2.1 Kasvustojen kuvaamiseen soveltuvat pienoislma-alukset.....	10
2.1.1 Kiinteäsiipiset dronet	10
2.1.2 Pyöriväsiipiset dronet	11
2.1.3 Pienoislma-aluksen rakenne.....	13
2.1.3.1 Dronen rakenne.....	13
2.1.3.2 ESC ja PDB.....	14
2.1.3.3 Flight Controller, Autopilot ja Power Module.....	14
2.1.3.4 GPS ja Air Speed Meter	15
2.1.3.5 R/C receiver, telemetry ja FPV	15
2.1.3.6 Gimbal	15
2.2 Dronejen lennättämistä koskeva lainsäädäntö Suomessa	19
2.2.1 Yleiset säädökset	19
2.2.2 Dronejen luokittelu kauko-ohjatukseksi ilma-alukseksi	21
2.2.3 Dronejen luokittelu lennokiksi	22
2.3 Peltolohkojen kaukokartoitus.....	22
2.3.1 Kaukokartoituksen perusteet	22
2.3.2 Kasvien heijastuksen tausta	23
2.3.3 Kasvuston ja maaperän erottaminen	24
2.3.4 Heijastunut säteily ja kasvuston viljelykasvien ominaisuuksista riippumattomat ominaisuudet.....	25
2.3.5 Heijastunut säteily ja kasvin stressi	26
2.3.6 Lannoitus.....	27
2.4 Kuvausolot Suomessa	29
2.5 Kasvustojen kuvaamisessa käytetyt kameratyypit.....	30
2.5.1 Pankromaattinen kamera	30
2.5.2 Multi- ja superspektrikamera	30
2.5.3 Hyper- ja ultraspektrikamera	30
2.6 Kasvillisuusindeksit ja aallonpituudet.....	31
3. TUTKIMUKSEN TAVOITTEET	38
4 AINEISTO JA MENETELMÄT	39
4.1 Koelohkot ja niiden viljely.....	39
4.2 Kuvausdrone ja multispektrikamera	40
4.3 Lohkojen kuvaukset	41
4.4 Lentotehtävät ja kuvien käsittely	41
4.5 Referenssinäytteet.....	45
4.6 Lehtialaindeksi-, lehtivihreä- ja biomassamittaukset	46
4.7 Pikseleiden arvojen määrittäminen	48
4.8 Tulosten tarkempi rajaaminen	48
4.9 Tulosten esitys	48
5 TULOKSET	49
5.1 Koirasuon B-osa ennen ensimmäistä niittoa	49
5.2 Isokytö ennen ensimmäistä niittoa	55
5.3 Koirasuon A-osa ennen toista niittoa	62

5.4	DLS anturista johtuvat kuvausvirheet	69
5.5	Lohkojen yhdistetyt biomassa- ja heijastusarvot	70
6	TULOSTEN TARKASTELU	72
6.1	Kuvausvirheet	72
6.2	Biomassan määrän arviointi	73
6.3	Pikselien arvot ja biomassa	73
6.4	Referenssinäytehavainnot ja kasvillisuusindeksit	74
6.5	Muuta havaittua	77
7	JOHTOPÄÄTÖKSET	78
8	KIIITOKSET	78
	LÄHTEET	79
	LIITE 1. KOIRASUON ILMAKUVA	88
	LIITE 2. ISOKYRÖN ILMAKUVA	88
	LIITE 3. KOIRASUON SALAOJAKARTTA	89
	LIITE 4. KOIRASUON B-OSAN 1. SADON KORJUUAIKANÄYTTEEN HAVAINNOKOHTAISET TULOKSET	90
	LIITE 5. KOIRASUON B-OSAN YLEIS- JA KASVUSTOHAVAINNOT	90
	LIITE 6. KOIRASUON B-OSAN 1. SADON TÄYDENTÄVÄ KUVAUS 9.6.2017	91
	LIITE 7. KOIRASUON B-OSAN 1. SADON LEHTIALAINDEKSIMITTAUKSEN TUNNISTEKOHTAISET TULOKSET	92
	LIITE 8. ISOKYRÖN YLEIS- JA KASVUSTOHAVAINNOT	93
	LIITE 9. TÖYSÄ KEISALA, TÄYDENTÄVÄ KUVAUS 13.6.2017. KUVISSA VIRHETTÄ	93
	LIITE 10. TÖYSÄ KEISALA, TÄYDENTÄVÄ KUVAUS 18.6.2017. KUVISSA HIEMAN VIRHETTÄ	97
	LIITE 11. ISOKYRÖN 9.6.2017 KORJUUAIKANÄYTTEEN TUNNUSKOHTAISET TULOKSET	99
	LIITE 12. ISOKYRÖN 9.6.2017 LEHTIALAINDEKSIN TUNNISTEKOHTAISET TULOKSET	100
	LIITE 13. KOIRASUON A-OSAN 12.7.2017 KORJUUAIKANÄYTTEEN TUNNUSKOHTAISET TULOKSET	100
	LIITE 14. KOIRASUON A-OSAN KASVUSTO- JA YLEISHAVAINNOT	101
	LIITE 15. KOIRASUON A-OSAN 1. SADON EPÄONNISTUNUT KUVAUS 8.6.2017	101
	LIITE 16. KOIRASUON A-OSAN 13.7.2017 TUNNISTEKOHTAISET LEHTIALAINDEKSIMITTAUKSET	103

LYHENTEET JA SYMBOLIT

BVLOS	Suoran näköyhteyden ulkopuolella tapahtuva lentäminen (Beyond Visual Line- of- Sight)
CTR	Lento-asemien lähiauleet (Control Zone)
DIY	Itse rakennettava (Do It Yourself)
DLS	Kirkkauden säätövalosensori (Downwelling Ligh Sensor)
Drone	Kansanomainen nimitys miehittämättömälle laitteelle maassa, vedessä ja ilmassa
DSM	Pintamalli (Digital Surface Model)
EASA	Euroopan lentoturvallisuusvirasto (European Aviation Safety Agency)
EFHK CTR SOUT	Helsinki-Vantaan lentoaseman eteläinen lähialue
ESC	Pyörimisnopeudenhallinnan mikrokontrolleri (Eletronic Speed Controller)
EVI	Parannettu kasvillisuusindeksi (Enhanced Vegetation Index)
EVLOS	Suora näköyhteys käyttäen kauko-ojaustähystäjää (Extended Visual Line-of- Sight)
FIZ	Lentotiedotusvyöhyke (Flight Information Zone)
FPV	Kameran reaaliaikainen videonäkymä (First-person View)
GPS	Maailmanlaajuiden paikallistamisjärjestelmä (Global Positioning System)
IMU	Inertia mittaus (Inertia Measurement Unit)

Indeksikartta

Indeksikartta tarkoittaa pieneltä alueelta otettua karttaotantaa johon on sidottu tietoa esim. heijastuksen voimakkuus eri alueilla.
Indeksi on esitetty yhteismitallisesti yksiköittömänä arvona.

Kaukokartoitus

Kaukokartoitus tarkoittaa tietojen keräämistä sähkömangneettisen säteilyavulla ilman fyysistä kosketusta itse kohteeseen.

Kauko-ohjattu ilma-alus

Ammattimaiseen lentotyöhön käytettävän dronen nimitys

LAI	Lehtialaindeksi (Leaf Area Index)
-----	-----------------------------------

Lennokki	Lentämiseen käytettävän dronen nimitys, kun sitä käytetään harraste- tai urheilutarkoitukseen
NDRE	Normalisoitu Red Edge indeksi (Normalised Difference Red Edge Index)
NDVI	Normalisoitu kasvillisuusindeksi (Normalized Difference Vegetation Index)
Ortomosaiikki	Kuva, joka on luotu yhdistämällä useita kuvia ja josta on vääristymät korjattu
PDB	Virranjakolevy (Power Distribution Board)
RMZ	Radiovyöhyke (Radio Mandatory Zone)
RPA	Kauko-ohjattu ilma-alus tai miehittämätön ilma-alus, jota käytetään lentotyöhön (Remote Piloted Aircraft)
RPAS	Kauko-ohjattun ilma-aluksen tai miehittämätömän ilma-aluksen kokonaisjärjestelmä (Remote Piloted Aircraft System)
Spektri	Säteilyn intensiteetin aallonpituus ja taajuusjakauma
Trafi	Liikenteen turvallisuusvirasto
TVI	Muutettu kasvillisuusindeksi (Transformed Vegetation Index)
UA	Miehittämätön ilma-alus (Unmanned Aircraft)
UAS	Ilma-aluksen kokonaisjärjestelmä (Unmanned Aerial Aircraft)
UAV	Sama kuin UA. Miehittämätön ilma-alus (Unmanned Aerial Vehicles)
VI	Kasvillisuusindeksi (Vegetation Index)
VLOS	Suora näköyhteys (Visual Line of Sight)

1. JOHDANTO

Suomen pohjoisesta sijainnista johtuen peltokasvien kasvukausi on lyhyt. Erityisesti tämä vaikuttaa erilaisten viljelykasvien menestymiseen täällä sekä aiheuttaa omat haasteensa maatalouden harjoittamiseen. Hehtaarisadot sekä peltojen keskipinta-alat ovat Suomessa huomattavasti pienempiä kuin esimerkiksi Keski-Euroopassa (FAOSTAT 2016). Meillä myös viljelymahdollisuudet ovat rajallisemmat, sillä kaikki kasvit eivät täällä menesty, johtuen lyhyestä kasvukaudesta. Suomessa karjalle tarkoitettujen rehujen viljely rajoittuu lähinnä nurmen, kauran (*Avena sativa*) ja ohran (*Hordeum vulgare*) viljelyyn, kun taas Keski-Euroopassa karjaa ruokintaan lähinnä maissisäilörehun (*Zea mays*) ja nurmisäilörehun eri sekoitussuhteilla ja nurmia tuotetaan laajemmalla kasvivalikoimalla (Peltonen ym. 2010, FAOSTAT 2016).

Maatilojen keskikoko on kasvanut viime vuosina Suomessa, ja tilakoon kasvun odotetaan jatkuvan lähitulevaisuudessa (MTK 2014). Vuonna 2014 Suomessa oli yhteensä 52 775 maatalous- ja puutarhayritykseksi luokiteltua tilaa, joista 11 887:llä harjoitettiin joko maidontuotantoa tai muuta karjataloutta (Luke 2014). Säilörehua korjattiin yhteensä 451 700 hehtaarin alalta vuonna 2010 (Tike 2013). Suomessa korjattava säilörehusato oli vuonna 2010 yhteensä 8,1 miljardia kiloa (Luke 2011). Tuotantomäärät ovat säilyneet ennallaan, vaikka tuotanto on entistä harvempien tilojen käsissä (MTK 2014). Suomen TNS Gallup Elintarviketieto Oy (2016) teettämän kyselyn mukaan maatalous- ja puutarhayritykseksi luokiteltujen tilojen määrä laskee 37 100 tilaan ja keskikoko kasvaa 62,1 hehtaariin vuoteen 2022 mennessä. Nautatilojen lukumäärän ennustetaan laskevan 6420 tilaan vuoteen 2022 mennessä (TNS 2016). Vuoden 2018 lopussa nautatiloja oli yhteensä 10 530 kpl ja maatalous- ja puutarhayritykseksi luokiteltuja tiloja 48 688 kpl (Luke 2019).

Nurmentuotannon suunnittelun lähtökohtana on karjan rehutarve (Peltonen ym. 2010). Tuotantoa on hyvä suunnitella useamman vuoden aikajänteellä, sillä suunnittelun avulla voidaan mitoittaa peltojen viljelykierto ja käyttö karjan rehujen tarpeisiin nähden (Peltonen ym. 2010). Lohkokirjanpitoon kirjatut viljelytoimenpiteet ja niiden toteutuksesta syntynyt sato tuottavat tietoa siihen, mikä on paras viljelytekniikka ja millä tuotantopanosten käytöllä päästään parhaimpaan laadulliseen, määrälliseen ja taloudelliseen tulokseen (Anttila ym. 2014, Peltonen ym. 2010).

Rehutuotantoon tarvittavan pinta-alan määrittämisessä nurmen keskisato (kg ka/ha) on hyvä olla tiedossa (Peltonen ym. 2010). Yksinkertainen tapa on määrittää tilalla tuotettavan nurmisadon keskisadot, jotka voidaan laskea karjan kokonaisrehunkulutuksen ja käytetyn väkirehumäärän erotuksena huomioiden mahdolliset rehuhävikit ja rehujen myynnit (Peltonen ym. 2010). Kun tämä laskelma jaetaan nurmentuotantoon käytetyllä pinta-alalla, saadaan tilan todellinen keskisato ja se voidaan laskea tarvittaessa useammalta vuodelta. NurmiArtturi-hankkeessa (2014) tilojen lohkojen välillä havaittiin isoja eroja alhaisimman ja korkeimman nurmisadon välillä ja eroksi saatiin jopa 4 000 kg ka/ha. Peltonen ym. (2010) pitää keskimääräisen nurmisadon hyvänä tavoitteena yli 6000 kg ka/ha.

Peltosen ym. (2010) mukaan nurmen uudistamien on kallis ja työläs toimenpide ja täydennyskylvön avulla voidaan siirtää nurmen uudistamista myöhemmään ajankohtaan. Kylvön avulla voidaan paikata aukkopaiikkoja, vähentää aukkopaikoissa kasvavien rikkakasvien määrää, tihentää kasvustoja, parantaa sadon laadullista arvoa sekä ylläpitää sadon määrää. Lisäksi toimenpiteellä voidaan korjata kasvuston talvivaurioita (Peltonen ym. 2010).

Tilakoon kasvaminen tekee kasvustojen tarkkailusta nykyistä haasteellisempaa. Laajat nurmiviljelypinta-alat ja niiden tehokas tuotanto vaativat oikea-aikaiset ja oikeat toimenpiteet. Kasvustojen tarkkailu pellon reunalta on usein haastavaa, eikä kokonaiskuvaa kasvustosta saada luotettavasti. Tarkkailu ilmasta auttaa kokonaiskuvan muodostamisessa sekä oikeiden toimenpiteiden valinnassa. Ilmasta käsin tarkasteltaessa saadaan hyvin kattava kokonaiskuva, mutta kasvusto näyttää hyvin erilaiselta pellon reunalta tarkasteltuna, mikä vaatii käyttäjältä hieman erilaista harjaantuneisuutta ja uudenlaista silmää kasvuston arvioinnille.

Tässä työssä keskityttiin nurmikasvustojen tarkkailu mahdollisuuksiin ja -haasteisiin ilmasta käsin miehittämättömään ilma-alukseen kiinnitettävän multispektri kameran avulla. Lisäksi syvennyttiin ilma-alusten tekniikkaan, käyttöominaisuuksiin sekä kasvustoindeksi karttojen kertomaan kasvuston tilasta.

2. KATSAUS KIRJALLISUUTEEN

Seuraavassa luvussa käsitellään yleisesti miehittämättömien pienoasilma-alusten toimintaperiaatetta, tekniikkaa ja lainsäädäntöä Suomessa sekä kaukokartoituksen peruseriaatteita, eri kameratyyppejä ja välineistöä. Luvussa keskitytään myös eri kasvillisuusindeksien ominaisuuksiin sekä niiden ja kasvuston fysiologisen tilan yhteyteen. Eri karttatyyppejen kuten pysty ja viistokuvien tarkastelu sekä kuvausvirheiden tarkastelu rajataan tämän kirjallisuusosion ulkopuolelle.

2.1 Kasvustojen kuvaamiseen soveltuvat pienoasilma-alukset

Pienoisilma-alukset voidaan jaotella useaan luokkaan niiden tyypin ja teknisen rakenteen perusteella (Ruini 2011, Elliott 2016). Keskeisimmän jaottelun perusteella pienoasilma-alukset luokitellaan tyypin perusteella joko kiinteäsiipisiin eli niin sanottuihin perinteisiin lentokonemallisiin tai multikoptereihin eli helikopteri-tyyppisiin ratkaisuihin (Ruini 2011, Halliday 2017). Elliottin (2016) mukaan laitteet luokitellaan usein myös painon perusteella painoluokkiin sekä rakenteen perusteella joko itse rakennettaviin DIY (Do It Yourself) tai valmiisiin kaupallisiin ratkaisuihin.


2.1.1 Kiinteäsiipiset dronet

Kiinteäsiipisissä eli niin sanotussa lentokonemallisissa lentokoneissa potkurin voi sijoittaa koneen etuosaan tai sen taakse. Potkurilla on näissä tilanteissa joko työntävä tai vetävä vaikutus (Halliday 2017). Rupertin (2017) mukaan, jos potkuri on sijoitettu laitteen etupuolelle, se voi haitata eteenpäin suunnatun kameran näkymää. Alueellisessa ilmakuvauksessa potkurin sijoittamisella ei ole merkitystä, sillä kuvat otetaan pääsääntöisesti suoraan alaspäin eikä potkuri tällöin ole kuvien tiellä (Elliott 2016).

Lentokonemalli on myös paljon herkempi tuulen vaikutuksella kuin multikopteri suuremman tuulen vaikutuspinta-alan johdosta. Mallia voi ohjata ylös, alas ja molemmille sivuille, mutta ei taaksepäin (Elliot 2016). Lentokonemallin haitta multikopteriin verrattuna on se, että liikkuu jatkuvasti eteenpäin, laite on aerodynamiikaltaan vaativa ja se on herkkä pyörimiselle, mikäli autopilotti ei ole käytössä (Ruini 2011). Hallidayn (2017) mukaan lentokone on parempi vaihtoehto kuin multikopteri, jos on kartoitettava iso alue nopeasti. Lentokonemallin lentoaika on huomattavasti pidempi verrattuna multikoptereihin (Elliot 2016).

2.1.2 Pyöriväsiipiset dronet


Elliotin (2016) ja Hallidayn (2017) mukaan pyöriväsiipiset lennokit jaetaan kahteen luokkaan karkeasti siipien lukumäärän perusteella: helikoptereihin eli niin sanottuihin tavallisiin koptereihin ja multikoptereihin, joissa on useita nostetta synnyttäviä roottoreita. Multikopterit ovat nimetty latinalaisen numerointijärjestelmän mukaan eli, jos on neljä roottoria, niin se on nelikopteri ja vastaavasti, jos on kuusi roottoria, se on heksakopteri (Elliot 2016). Mallista riippuen roottorit voivat olla sijoitettuna myös päällekkäin kuten Kuva 1 Y6-mallin heksakopterissa. Kopterien numerointijärjestelmä ja roottorien pyörimissuunnat on esitetty Kuva 1.



Kuva 1. Multikoptereiden rakenteet. Muokattu lähteestä (TUG Team 2014).

Rupertin (2017) mukaan multikopterit on helpompi rakentaa kuin perinteiset lentokonemalliset ilma-alukset, sillä aerodynaamiset vaatimukset eivät ole niin vaativat kuin lentokonemalleissa. Multikopterit ovat myös vakaita lennättää, mikä tekee niistä suosittuja kuluttajien keskuudessa. Pyörivät sähkömoottorit synnyttävät nosteen, joka mahdollistaa multikopterin lentämisen. Syntyvään nosteeseen vaikuttavat useat ominaisuudet, kuten siipien sijainti, lukumäärä, siipien ominaisuudet, sähkömoottorien ominaisuudet ja laitteen rungon muotoilu (Halliday 2017, Rupert 2017).

Tavallista helikopteria hallitaan kääntelemällä lapojen kulmaa (Ruini 2011, Elliott 2016). Yksi iso roottori (yaw, Kuva 2) synnyttää voimakkaan vääntövoiman vastakkaiseen suunaan roottorin pyörimissuuntaan nähden. Voimakas vääntömomentti kumotaan rungon päässä olevalla kallistus (pitch, Kuva 2) moottorilla, joka pitää kopterin myös oikeassa suunnassa. Halliday (2017) mukaan tavalliset harrastukseen suunnatut yksiroottoriset helikopterit ovat haastavia rakentaa ja ne ovat vaarallisempia käyttäjälle suuren roottorinsa vuoksi. Lisäksi yksiroottoristen helikopterien vakaus- ja hallittavuusominaisuudet ovat huomattavasti heikommät kuin multikoptereissa (Elliott 2016).



Kuva 2. Kameran vakaimen aksiaalisuunnat. Kuva Juho Kotala 2017.

Multikoptereissa roottorin synnyttämä vääntövoima kumotaan toisella vastakkaiseen suuntaan pyörivällä roottorilla. Pyörimisnopeutta säätelemällä voidaan vaikuttaa nosteen ja vääntömomentin suuruuteen. Hidastamalla X-nelikopterin (Kuva 1) etummaisten roottorin pyörimisnopeutta ja kasvattamalla taaimmaisten roottorin pyörimisnopeutta, saadaan kopteri lentämään haluttuun suuntaan (Elliott 2016, Halliday 2017, Rupert 2017).

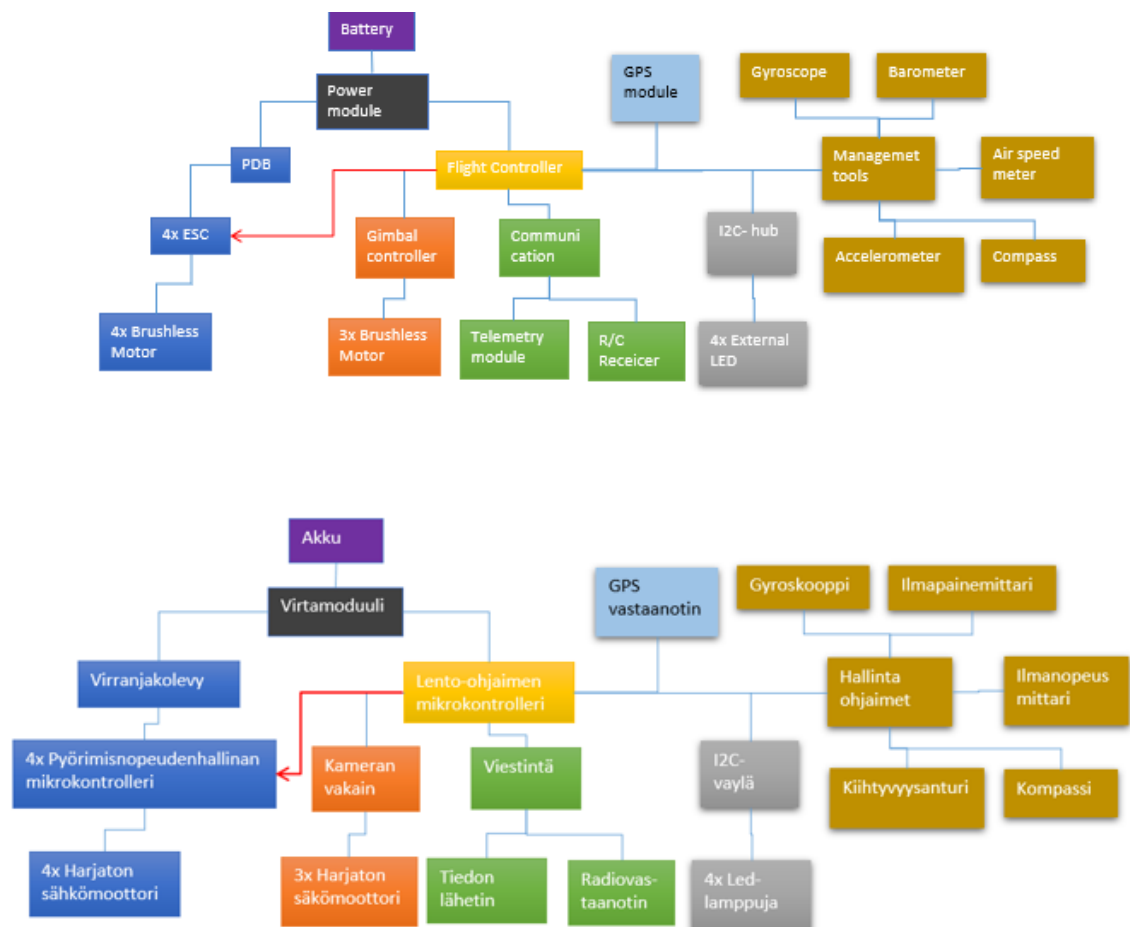
Heksa- ja oktokoiterit sekä näitä useampi roottoriset kopterit ovat vakaampia käytössä kuin nelikopterit (Rupert 2017). Vakaus korostuu erityisesti laskeutumisessa ja vaativissa tehtävissä, kuten ammattimaisissa kuvauksissa ja kartoitustyössä (Halliday 2017). Rupertin (2017) mukaan useammat roottorin lisäävät kuormankantokykyä ja yhden tai useamman roottorin toimintahäiriö ei ole niin kriittistä kuin heli- ja nelikoptereilla. Multikopterit soveltuvat parhaiten pienten alueiden sekä rajallisten laskeutumisalueiden kartoitustyöhön (Elliott 2016).

2.1.3 Pienoisilma-aluksen rakenne

Tässä luvussa käsitellään dronen teknistä rakennetta, toimintaperiaatetta ja vaadittavaa kokoonpanoa, jotta automaattisia lentotehtäviä voidaan lentää. Osiossa painotetaan pyöriväsiipisten dronejen kokoonpanoa, mutta vastaavaa kokoonpanoa voi soveltaa myös kiinteäsiipisten osalta. Kasvustojen kuvaukseen paneudutaan myöhemmässä luvussa.

2.1.3.1 Dronen rakenne

Kokonaisjärjestelmästä käytetään usein lyhennettä UAS (Unmanned Aerial Aircraft). Järjestelmään sisältyy ilma-alus ja sen käyttöön vaadittavat osat (Trafic 2017a). Kokonaisjärjestelmä koostuu itse lentokoneesta, sen ohjaamiseen vaadittavasta ohjainyksiköstä ja tabletista/tietokoneesta, joita käytetään lentokoneen hallintaan (Halliday 2017). Nelikopterin sisällä olevat toiminnan edellyttämät osat on esitetty Kuva 3.



Kuva 3. Nelikopterin hallintalaitteiden pelkistetty rakenne. Rakenne esitetty sekä suomeksi että englanniksi selvyiden vuoksi. Osalle komponenteista ei ole suomeksi vakiintunutta käännössanaa. Muutettu alkuperäisetä lähteestä (Elliott 2016).

2.1.3.2 ESC ja PDB

Electronic Speed Sensor tarkoitetaan pyörimisnopeudenhallinnan mikrokontrolleria. Lentokoneissa käytetään harjattomien sähkömoottoreiden (Brushless Motor) ohjaukseen eli roottorien pyörimismoottorin hallintaan (Halliday 2017). Harjattomien moottorin käyttö edellyttää jokaiselle moottorille oman ESC:n (Baichtal 2015). Mikrokontrolleri muuttaa tasavirran (DC) vaihtovirraksi (AC) ja ajoittaa moottoreille syötettävän virran autopilotin käskyjen mukaan eli sovittaa moottorin pyörimisnopeuden tilanteeseen soveltuvaksi (Baichtal 2015, Rubert 2017). Jossain tilanteissa ESC:tä käytetään myös vakaimen eli gimbaalin harjattomien sähkömoottorien sekä servojen ohjaamiseen (Elliott 2016). Power Distribution Board (PDB) eli virranjakolevy jakaa akulta tulevan virran eri roottorien moottoreiden välillä (Elliott 2016).

2.1.3.3 Flight Controller, Autopilot ja Power Module

Flight Controller eli lento-ohjaimen mikrokontrolleri. Pitää lentokoneen orientaation haluttuna ohjaamalla roottorien pyörimisnopeutta (Halliday 2017). Autopilot eli automaattisten lentojen hallinnan mikrokontrolleri mahdollistaa automaattisten lentotehtävien suorittamisen lentokoneella (Elliott 2016). Hallidayn (2017) mukaan useat automaattisten lentojen hallinnan ohjaimet sisältävät vähintään gyroskoopin eli kulmanopeusanturin, kiihtyvyysanturin, ilmanpainemittarin sekä kompassin. Kompassi tunnistaa lentokoneen lentosuunnan maan magneettikentästä. Ilmanpainemittari mittaa lentokorkeuden mukaan muuttuvaa ilmanpainetta ja laskee tämän perusteella lentokorkeuden (Rubert 2017). Kiihtyvyysanturia ja gyroskooppia käytetään lentokoneen apuna vakauden hallinnassa lennon aikana. Virtamoduuli eli Power Module mittaa akun varausta ja kertoo varauksen tilan lento-ohjaimen mikrokontrollerille. Moduulin avulla voidaan estää akun varauksen loppuminen lennon aikana ja estää siitä aiheutuva hallitsematon laskeutuminen (Baichtal 2015, Elliott 2016, Halliday 2017, Rupert 2017).

2.1.3.4 GPS ja Air Speed Meter

Droneissa käytetään yleensä maailmanlaajuinen paikallistamisjärjestelmää GPS (Global Position System) pääasiallisena välineenä sijainnin määrittämiseen (Halliday 2017). Ilmanopeusmittaria eli Air Speed Meter käytetään ilmanopeuden määrittämiseen. Lentämisen aikana tuuli vaikuttaa droneen, joten ilmanopeus voi olla eri kuin maanopeus (Baichtal 2015, Elliott 2016).

2.1.3.5 R/C receiver, telemetry ja FPV

Dronen etähallintaa varten vaaditaan kauko-ohjain. R/C Receiver eli radiovastaanotin, vastaanottaa ohjainyksiköltä lähetettyjä viestejä (Ruini 2011). Radiovastaanotin käyttää useita kanavia ja yhdellä kanavalla on aina yksi tehtävä. Tehtävä eli viesti voi esimerkiksi olla käänä vakaimen ”Roll” moottoria. Radiolähettimessä ja vastaanottimessa on molemmissa yhtä monta kanavaa ja kanavien määrä rajoittaa yhtäaikaisten ohjausten maksimimäärän (Ruini 2011, Baichtal 2015, Elliott 2016.) Elliott (2016) mukaan radiovastaanottimessa yleisesti käytetty taajuus on 2,4 GHz.


Telemetry-termillä tarkoitetaan tiedon lähetintä, joka lähettää ohjussyksikölle kuvasignaalia ja anturitietoja lentokoneen tilasta (Elliott 2016). Telemetry on valinnainen varuste. Laite toimii usella kanavalla yhtäaikaaisesti ja mahdollistaa useiden käskyjen lähettämisen samanaikaisesti. First Person View (FPV) on telemeryn erillinen ominaisuus eli videolinkki, joka lähettää kameran reaaliaikaista videonäkymää vastaanottimelle erillistä kanavaa käyttäen (Baichtal 2015). Baichtal (2015) ja Elliottin (2016) mukaan useat kaupalliset dronet käyttävät 5,8 GHz:n taajuutta videonäkymän lähettämiseen, koska korkeamman taajuuden käyttö mahdollistaa suuremman tietomäärän lähettämisen.

2.1.3.6 Gimbal

Elliottin (2016) mukaan gimbal eli kameran vakain on laite, joka pitää kameran orientaation haluttuna miehittämättömän ilma-aluksen liikkuessakin tai tuulen osuessa laitteeseen. Vakaimen moottoreina käytetään joko harjattomia sähkömoottoreita tai servoja (Elliott 2016, Baichtal 2015). Vakaimen servoja tai sähkömoottoreita voi ohjata lennon aikana eli kameran asentoa suhteessa ilma-alukseen voi muuttaa (Baichtal 2015). Harjattomat sähkömoottorit ovat nykyisin yleistyneet vakaimen moottoreina niiden

paremman vakauden ansiosta verrattuna servoihin (Elliott 2016). Kameran vakain on havainnollistettu Kuva 2.

Vakaimissa käytettävät harjattomat sähkömoottorit ovat samoja, joita käytetään roottorien moottoreina, mutta niihin on pyritty säätämään mahdollisimman suuri vääntömomentti ja pieni teho (eli pieni KV -arvo). Roottorien moottorit ovat vastaavasti säädetty tuottamaan mahdollisimman suuri teho (KV). Vakain voi olla joko yksi-, kaksi- tai kolmeakselinen. Kolmiakselinen vakain mahdollistaa kameran asennon säilymisen muuttumattomana kulkusuunnasta riippumatta (Elliot 2016, Halliday 2017). Tässä tutkimuksessa käytetyn Red Edge kameran vakain on havainnollistettu Kuva 4. Vastaavasti Kuva 2 on esitetty vakaimen aksiaalisuunnat.



Kuva 4. 3dr solo -nelikopteri ja Red Edge kamera vakaimella varustettuna. GPS (Global Position System) = maailmanlaajuinen paikallistamisjärjestelmä, DLS (Downwelling Light Sensor) = kameran kirkkauden säätövalosensori ja IMU (Inertia Measurement Unit) = inertia mittaus. Yaw, Roll ja Pitch ovat vakaimen tasapainotuksessa käytettäviä harjattomia sähkömoottoreita tai servoja. Kuva Juho Kotala 2018.

Parhaan mahdollisen vakaimen suorituskyvyn takaamiseksi vakain on tasapainotettava niin, että sen painovoiman keskipiste ja geometrinen keskipiste ovat mahdollisimman lähellä toisiaan (Ruini 2011). Tämä korostuu käyttäessä raskasta kameraa kuten järjestelmäkameraa tai multispektrikameraa, kuten tässä työssä käytetty RedEdge (Ruini 2011, Elliot 2016). Mikäli kameran massakeskipisteen sijainti poikkeaa vakaimen geometrisesta keskipisteestä, täytyy moottorin tehdä koko ajan töitä pitääkseen kameran halutussa asennossa. Tämä lyhentää lentoaikaa sekä saattaa edellyttää suurempitehoisen moottorin käyttöä (Elliott 2016).

Vakaimessa kameran asento mitataan inertia mittauksella IMU:n (Inertia Measurement Unit) avulla (Halliday 2017). Inertiamittauksessa kameran asento mitataan suurella taajuudella ja tieto viedään edelleen kameran asentoa ohjaavalle ohjaimelle (Rupert

2017). Kuva 4 IMU on asennettu kameran päälle mittaamaan kameran asentoa. Hallidayn (2017) mukaan useimmissa ohjainpiireissä on kaksi inertiamittausyksikköä, joista toinen voi olla rakennettu ohjainpiirien sisälle ja toinen voidaan asentaa mittaamaan kameran asentoa kameran pinnalle. Kahta inertiamittausyksikköä käyttämällä saadaan asentotieto sekä kameraa lennättävästä laitteesta, että kamerasta mikä edelleen parantaa kameran asennon vakautta (Elliott 2016).

2.2 Dronejen lennättämistä koskeva lainsäädäntö Suomessa

Dronet yleistyvät nopeasti kuluttajien keskuudessa ja ilman käyttörajoituksia toiminta väärässä paikassa saattaa aiheuttaa vaaratilanteita. Nykyisin voimassa oleva säädös (OPS M1-32) on ollut voimassa vuoden 2016 alusta (Trafi 2016). Valmisteilla on uusi EU:n laajuinen direktiivi, joka on tulossa voimaan alustavasti 2019 (Eurooppa-neuvosto 2018). Lainsäädäntöön liittyvät määräykset ja ohjeet koskevat myös tutkimustyötä ja sen vuoksi aihetta käsitellään tässä työssä.

2.2.1 Yleiset säädökset

Lennokin ja miehittämättömän ilma-aluksen lennättämisen lainsäädäntö Suomessa perustuu liikenteen turvallisuusviraston (Trafin 2016) antamaan OPS M1-32 säädökseen lentotoiminnasta. Säädöksen perustana on ilmailulaki (864/2014) 9, 57, 70 § ja säädös on toistaiseksi voimassa. Nykyinen voimassa oleva säädös astui voimaan 1.1.2017 ja sillä kumottiin aiemmin voimassa ollut OPS M-32 säädös, joka oli annettu 9.10.2015.

Dronejen käytöstä maa- ja metsätaloudenlentotoimintaan ei ole erityistä säädöstä voimassa vaan niihin sovelletaan OPS M-32 säädöstä: kauko-ohjatun ilma-aluksen ja lennokin lennättäminen (Trafi 2016). Tutkielman aineiston keruun aikana voimassa ollut lainsäädäntö on tässä luvussa käsitelty niiltä osin, kun se on vaikuttanut tutkielman aineiston keräämiseen. EU:n eli Euroopan Unionin uuteen lentodirektiiviesitykseen tai valmisteilla oleviin kansallisiin lennättämisen säädösten muuttamiseen ei oteta kantaa. OPS M-32 säädöstä sovelletaan kauko-ohjattujen ilma-alusten ja yli 250 g painavien lennokkien lennättämiseen Suomessa. Määräys ei koske sisätiloissa tapahtuvaa lennättämistä tai sotilasilmailua.

Lennokilla tai miehittämättömällä ilma-aluksella lentoasemien lähialueella (CTR, Control Zone), lentopaikan lentotiedotusvyöhykkeellä (FIZ, Flight Information Zone) tai radiovyöhykkeellä (RMZ, Radio Mandatory Zone) on sallittua enintään 50 metrin korkeudessa, kun vaakasuora etäisyys kiitotiestä on vähintään viisi kilometriä (Trafi 2016). Säädöksen mukaan: ”jos tarve on lennättää korkeammalla kuin 50 metriä, asiasta on sovittava erikseen ilmaliikennepalvelujen tarjoajan kanssa”. Lisäksi alle viiden kilometrin päässä kiitotiestä tapahtuva lennättäminen on aina sovittava ilmaliikennepalvelujen tarjoajan kanssa. Poikkeuksena on EFHK CTR SOUT alue, jossa Koirasuon koelohko sijaitsee. Lennättämisestä siellä on sovittava kaikissa tilanteissa

Helsinki-Vantaan (EFHK) liikennepalvelujen tarjoajan kanssa. Kaikilla alueilla, jotka eivät kuulu lennättämisen kieltoalueisiin, rajoitusalueisiin tai vaara-alueisiin on lennätyskorkeus rajattu 150 metriin maan tai veden pinnasta mitattuna (Trafi 2016). Ajankohtaiset kielto-, rajoitus- tai vaara-alueet voit tarkistaa (droneinfo.fi) -sivustolta. Tämän työn Töysän koelohkot sijaitsivat lentorajoitusalueiden ulkopuolella.

Droneilla tarkoitetaan kansanomaista nimitystä kaikille miehittämättömille laitteille maassa, vedessä ja ilmassa. Dronet luokitellaan ilmailukäytössä lennokiksi tai kauko-ohjatuiksi ilma-aluksiksi käyttötarkoituksen perusteella. Sama laite voi kuulua kumpaan luokkaan tahansa riippuen käyttötarkoituksesta. Lennokiksi laite määritellään silloin, kun sitä käytetään harraste- tai urheilutarkoitukseen. Vastaavasti laite luokitellaan kauko-ohjatuksi ilma-alukseksi silloin, kun sitä käytetään lentotyöhön ja muuhun kuin harraste tai urheilukäyttöön (Trafi 2017a).

Lennokin tai kauko-ohjatun ilma-aluksen lennot jaotellaan kolmeen osaan sen perusteella, onko laitteeseen näköyhteys. Suora näköyhteys (Visual Line- of- Sight, VLOS) tarkoittaa lennättämistä siten, että lennättäjällä on suora näköyhteys laitteeseen ilman apuvälineitä. Suora näköyhteys käyttäen kauko-ohjaustähystäjää (Extended Visual Line- of- Sight, EVLOS) tarkoittaa lentämistä siten, että lentäjää avustavalla henkilöllä on suora näköyhteys laitteeseen. Suoran näköyhteyden ulkopuolalla tapahtuva lentäminen (Beyond Visual Line- Of- Sight, BVLOS) eli suoran näköyhteyden ulkopuolella tapahtuva lentäminen tarkoittaa sitä, että lennättäjä pitää apuvälineiden avulla yhteyttä laitteeseen (Trafi 2017a).

Lennokeista sekä kauko-ohjatuista ilma-aluksista käytetään paljon lyhenteitä niin kirjallisuudessa kuin säädöksissä. Lyhennettä UA (Unmanned Aircraft) tarkoittaa säädöksessä miehittämätöntä ilma-alusta, joka on tarkoitettu lentämään ilman ohjaajaa. Lyhenne korvaa aiemmin käytetyn lyhenteen (Unmanned Aerial Vehicles), mutta tällä termillä ei kuitenkaan tarkoiteta lennokkia. UAV lyhennettä vastaavasti käytetään kirjallisuudessa. RPA (Remote Piloted Aircraft) tarkoitetaan säädöksessä kauko-ohjattua ilma-alusta tai miehittämätöntä ilma-alusta, jota käytetään lentotyöhön. Säädöksessä olevaa RPA -laitetta lennetään kauko-ohjauspaikasta. RPAS (Remote Piloted Aircraft System) tarkoittaa kauko-ohjatun ilma-aluksen kokonaisjärjestelmään, johon kuuluvat kauko-ohjauspaikka ja laitteen lentämiseen vaadittavat laitteistot ja yhteydet (Trafi 2017a).

2.2.2 Dronejen luokittelu kauko-ohjatukseksi ilma-alukseksi

Kauko-ohjattujen ilma-alusten lennättämisessä ei vaadita lentotyölupaa eikä lennättämiseen sovelleta muita lentotyöstä annettuja säädöksiä ja määräyksiä. Vaikka lentotyölupaa ei vaadita, niin ennen kauko-ohjatun ilma-aluksen käyttämistä siitä on tehtävä ilmoitus Trafille. Ilmoitukseen vaaditaan tiedot käyttäjästä, tekniset tiedot ilma-aluksesta, toiminnan laatu ja laajuus, tieto siitä, aiotaanko toimintaa harjoittaa asutuskeskuksen tiheästi asutulla alueella ja lennätetäänkö alusta väkijoukon päällä (Trafi 2016).

Lennätykset on tehtävä siten, että niistä aiheutuu vain mahdollisimman vähän vaaraa ulkopuolisille henkilöille tai heidän omaisuudella ja niin että meluhaitta on mahdollisimman vähäinen. Lennättämiseen vaaditaan aina myös vähintään 18 vuoden ikä. Dronessa on myös oltava varajärjestelmä siltä varalta, että yhteys katkeaa laitteeseen. Varajärjestelmän avulla se voidaan turvallisesti laskea alas. Lisäksi lennättäjällä on oltava toimintaohje yhteyden katkeamisen ja ongelmatilanteiden varalle (Trafi 2016).

Lennoista on pidettävä lentopäiväkirjaa, johon on merkittävä lennon päivämäärä, paikka, lennättäjä, ilma-aluksen valmistaja ja malli, lennätyksen alkamis- ja päättymiskellonaika, mainita mahdollisesta kauko-ohjaajatahystäjän käytöstä ja onko kyseessä suoraan näköyhteyteen perustuva lento VLOS vai näköyhteyden ulkopuolella tapahtuva toiminta BVLOS. Tiedot lennätyksestä on säilytettävä kolmen vuoden ajan (Trafi 2016).

Kauko-ohjatun ilma-aluksen on väistettävä muita ilma-aluksia ja väkijoukon päällä lennättäminen on kiellettyä ilman poikkeuslupaa. Näköyhteyden ulkopuolella tapahtuvat BVLOS tyyppin lennot ovat ilman poikkeuslupaa kiellettyjä (Trafi 2016). Kauko-ohjatuille ilma-aluksilla on oltava myös ilmailun vakuutusasetusten mukainen vakuutus (Euroopan parlamentin ja neuvoston asetus (EY) N.0 785/2004).

Opetuskäytössä tapahtuva lentäminen luetaan lentotoiminnaksi, vaikka opetuksesta ei perittäisi maksuja (Trafi 2017b). Liikenteen turvallisuusviraston Trafin 30.5.2017 uutiskirjeen perusteella lentotoimintaan lasketaan myös yliopiston tekemä tutkimus, jossa käytetään kauko-ohjattavia ilma-aluksia (Trafi 2017c).

2.2.3 Dronejen luokittelu lennokiksi

Lennokkien lennätykset on toteutettava siten, että niistä aiheutuva vaara ulkopuolisille henkilöille ja heidän omaisuudellensa sekä syntyvä meluhaitta ovat mahdollisimman vähäiset. Lennokkien lennättäminen väkijoukon päällä on kaikissa tapauksissa kielletty (Trafi 2016). Liikenteen turvallisuusviraston ohjeiden (2016) mukaan lennokin lennättämiseen ei ole ikärajaa.

Lentoonlähdomassaltaan korkeintaan 3 kg lennokin lennättäminen on sallittu tiheästi asutuilla alueilla asutuskeskusten yhteydessä. Asutuskeskuksella tarkoitetaan asutuskeskittymää, jossa on vähintään 200 asukasta ja asuinrakennusten etäisyys on toisistaan korkeintaan 200 metriä. Edellytyksenä tällä on, että lentäjä on tutustunut alueeseen, todennut laitteen olevan teknisesti kunnossa ja että lennokkia voidaan lennättää turvallisesti. Yli 3 kg painavan lennokin lennättäminen tiheästi asutulla alueella on kielletty (Trafi 2016).

Lennokista on käytävä ilmi sen käyttäjä ja yhteystiedot. Lentojen on oltava suoraan näkyvyyteen perustuvia (VLOS) lentoja. Lennättäminen videolinkin FPV (First Person View) avulla on sallittu, jos lentämisen varmistamiseksi käytetään vähintään yhtä avustajaa, jolla on suora näköyhteys lennokkiin. Edellä mainitussa tilanteessa avustajan ja lentäjän välillä on oltava suora puheyhteys ilman viestivälineitä. OPS M-32 säädöksen mukaan lennokin on myös väistettävä kaikkia muita ilma-aluksia. EU vakuutusasetus (EY) N.0 785/2004) ei koske lentoonlähdomassaltaan alle 20 kg lennokkeja, vaan niihin sovelletaan vahingonkorvauslakia (Trafi 2017c, EY N.0 785/2004).

2.3 Peltolohkojen kaukokartoitus

Seuraavassa osiossa käydään läpi kaukokartoituksen peruseriaatteita sekä paneudutaan kasvien ja maaperän heijastuksen taustaan. Osiossa on keskitytty erityisesti näkyvän valon sekä lähi-infrapunaa aallonpituusalueisiin.

2.3.1 Kaukokartoituksen perusteet

Kaukokartoitus tarkoittaa tietojen keräämistä sähkömagneettisen säteilyn avulla ilman fyysistä kosketusta itse kohteeseen (Holopainen ym. 2015). Knipling (1970) mukaan tietojen kerääminen perustuu sähkömagneettisen säteilyn heijastumiseen ja

absorboitumiseen kasvuston ja maan pinnalta. Heijastuksen ja imeytymisen intensiteetti riippuvat muun muassa kasvien fysiologista ominaisuuksista, maaperän geologista sekä hydrologisista olosuhteista (Knipling 1970). Yksittäisen kasvin havaitseminen lohkolta on haastavaa, sillä saman pikselin alle voi tallentua useampi kasvi, mutta suuren alueen kokonaiskuvan määrittämien on helpompaa (Knipling 1970). Kaukokartoitusta voidaan pitää tehokkaana työkaluna kasvillisuuden tutkimiseen paikallisesti, alueellisesti ja globaalissa mittakaavassa (Gitelson ym. 2006).

Knipling (1970) ja Thenkabailin (2016a) mukaan perinteisiä kaukokartoitusvälineitä ovat muun muassa satelliitit, lentokoneet ja leijat. Uutena menetelmänä voidaan pitää pienoissilma-aluksia kuten droneja (Thenkabailin 2016a). Holopaisen ym. (2015) mukaan kaukokartoitus jaetaan aktiiviseen ja passiiviseen kartoitukseen. Passiivisessa kaukokartoituksessa kerätään kohteen lähettämää ja heijastamaa säteilyä. Vastaavasti aktiivisessa menetelmässä on säteilylähde (esimerkiksi laserpulssi) ja tutkittava säteily on muista säteilylähteistä riippuen ainakin osittain peräsin heijastuslähteestä. Holopaisen ym. (2015) ja Thenkabailin (2016a) mukaan usein kaukokartoituksen apuna käytetään referenssiaineistoa, jota on kerätty maastosta tutkittavalta alueelta. Referenssiaineistoa käytetään sekä mittalaitteiden kalibrointiin, että tulosten tulkinnan oikeellisuuden varmistamiseksi (Holopainen ym. 2015).

2.3.2 Kasvien heijastuksen tausta

Kasvin lehdet voivat heijastaa, emittoida eli lähettää (emittio = fysikaalinen termi ominaissäteilyä lähettävälle kohteelle) ja absorboida energiaa samaan aikaan. Mittalaitteelle tuleva havainto muodostuu lehtien heijastamasta ja emittoimasta energiasta täystiheässä lehtikasvustossa (Thenkabailin 2016a ja 2016b). Knipling (1970) havaitsi tutkimuksessaan, kasvustosta voidaan tunnistaa stressitekijöitä kuten kuivuutta (tai märkyyttä), ravinnepuutoksia, kasvitauteja, lajikkeita toisistaan, kasvuston määrää ja tiheyttä. Useat tutkimukset (Richardson 1983, Jackson 1986, Hatfield 1993, Nilsson 1995, Pinter ym. 2003) tukevat Kniplingin (1970) havaintoa.


Knipling (1970) mukaan kasvien kyky heijastaa sähkömagneettista säteilyä ei ole vakio, vaan siihen vaikuttavat muun muassa mittaushetkellä tuleva auringon säteilyn määrä, mittalaitteen mittauskulma, kasvin lehtiala, mahdolliset varjot ja taustan ominaisuudet. Stressistä tai kasvitaudeista kärsivät kasvit aiheuttavat heijastukseen muutoksia (Tucker

1979, Campbell ja Randolph 2011). Heijastuksen muutoksia selittää usein kasvin lehtivihreäpitoisuuden muutos, mutta heijastuksessa voi olla vaihtelua, vaikka lehtivihreäpitoisuus mitattavan kasvin lehdessä ei ole muuttunut. Heijastuksen eroja on havaittavissa sekä näkyvän valon että lähi-infrapun -alueilla (Knipling 1970, Tucker 1979, Campbell ja Randolph 2011).

Jokaisella kasvilajilla on erilainen heijastusspektri. Tausta kasvillisuudesta poikkeavat heijastusarvot voidaan erottaa, kun kuvissa on riittävän suuri spatiaalinen resoluutio eli yhden pikselin alle jäävän alueen pinta-ala on riittävän pieni. käytetään riittävää tarkkuutta. Edellä mainittu menetelmä mahdollistaa vierasesineiden sekä rikkakasvien erottamisen kasvustosta (Campbell ja Randolph 2011, Thenkabailin 2016a ja 2016b). Chavan ja Nandedkar (2018) testasivat eri konenäköohjelmistoja automaattiseen rikkakasvien ja viljelykasvin tunnistamiseen orasvaiheessa RGB kuvista. Tutkimuksessa tunnistustarkkuudeksi saatiin keskimäärin $R^2=96$.

2.3.3 Kasvuston ja maaperän erottaminen

Kasvuston ja maaperän erottaminen toisistaan tapahtuu vertailemalla heijastus eroja kummastakin pinnasta (Thenkabailin 2016a). Paljas maaperä (Kuva 5) heijastaa voimakkaammin (8–30 %) sähkömagneettista säteilyä näkyvän valon alueella (400–700 nm) kuin kasvuston peittämän pinta (4–8 %). Vastaavasti lähi-infrapun alueella (700–1000 nm) maanpinta (Kuva 5) heijastaa vähemmän (18–32 %) kuin kasvuston peittämä alue (45–55 %). Kasvuston ja maaperän heijastus on erilainen samalla aallonpituudella ja näitä eroja tulkitsemalla voidaan erottaa kasvuston peittämät alueet paljaasta maanpinnasta (Knipling 1970, Tucker 1979). Kuva 5 on esitetty tulevan säteilyn heijastuminen nurmesta, irtovedestä ja maaperästä aallonpituuden funktiona.



Kuva 5. Nurmen, irtoveden, puiden varjojen, maaperän ja kuolleen kasvuston heijastuksen voimakkuus eri aallonpituusalueilla. Kuvassa aallonpituutena x-akseli ja y-akselina heijastuksen voimakkuus. Muokattu lähteistä (Knipling 1970, Berni ym. 2009, Campbell ja Randolph 2011).

2.3.4 Heijastunut säteily ja kasvuston viljelykasvien ominaisuuksista riippumattomat ominaisuudet

Knipling (1970) mukaan näkyvän valon aallonpituusalueella (400–700 nm) kasvien pinnat heijastava maksimissaan 10 % saamastaan sähkömagneettista säteilystä, sillä säteilyn absorptio on näillä aallonpituuksilla voimakasta. Vastaavasti lähi-infrapuna-alueella (700–1400 nm) tapahtuu voimakkaampi heijastus kuin näkyvän valon aallonpituusalueella, sillä säteilyn absorptio on tällä alueella vähäisempää. Lähi-infrapuna-alueelta siirryttäessä pidempään aallonpituusalueeseen eli keskipitkään infrapunaan (1400–2500 nm), lehdissä oleva vesi absorboi säteilyä ja heijastus on vähäisempää (Knipling 1970, Thenkabailin 2016a).

Kasvien lehtien pinnalla oleva irtovesi (Kuva 5) aiheuttaa kasvillisuutta voimakkaamman heijastuksen sinisen valon (400–500 nm) kodalla (Campbell ja Randolph 2011). Aamukasteen tai sateen jäljiltä tapahtuva kuvaus saattaa aiheuttaa häiriötä kuviin, kun


heijastukseen vaikuttaa kasvin lehdillä pisaroiva vesi (Campbell ja Randolph 2011, Thenkabailin 2016a ja 2016b). Kasvien solurakenteeseen sitoutunut vesi aiheuttaa absorptiokaistat lähi-infrapunan alueelle (1250–1350 nm) ja keskipitkän infrapunan alueelle (1675–1700 nm) (Campbell ja Randolph 2011).

Nurmikasveilla kasvuston kehitystason muuttuminen kasvun edetessä lisää tiettyyn pisteeseen asti kasvuston lehtialaa (Peltonen ym. 2010). Lehtialan lisääntyminen (Kuva 5) siirtää heijastuksen maaperän heijastuskäyrältä kasvuston heijastuskäyrälle (Knippling 1970, Tucker 1979). Heijastus lisääntyy lähi-infrapuna-alueella (700–1400 nm) ja vastaavasti pienentyy näkyvän valon alueella (400–700 nm) (Knippling 1970). Tucker (1979) ja Pöllösen ym. (2013) tekemät tutkimukset tukevat havaintoa ja heijastus muuttui edellä mainitulla lailla. Tuckerilla (1970) tutkittavana kasvina oli nurmi ja Pöllösellä ym. (2013) ohra ja vehnä.

Kuolleen tai kuivan kasvuston (Kuva 5) heijastus kasvaa 400 nm kohdalla (12 %) 800 nm (40 %) lineaarisesti (Tucker 1979, Thenkabailin 2016b). Thenkabailin (2016b) mukaan, mitä elinvoimaisempi kasvusto on, sen enemmän se heijastaa lähi-infrapuna valoa sekä näkyvistä valoista vihreää. Päisteissä ja ajourien kohdalla kasvusto on yleensä harvempaa ja saattaa kärsiä tallauksen aiheuttamasta abioottisesta stressistä ja tämä aiheuttaa heijastusominaisuuksiin muutoksia, joita voidaan havaita indeksikartoista (Tucker 1979, Thenkabailin 2016b, Zabala 2017). Kasvuston heijastuseroja vertailemalla kasvilajit voidaan erottaa toisistaan, rikkakasvit taustakasvillisuudesta ja havaintoja soveltaa esimerkiksi täsmäviljelyyn.

2.3.5 Heijastunut säteily ja kasvin stressi

Kasvien stressi jaetaan abioottiseksi ja bioottiseksi stressiksi (Jakson 1986). Abioottinen tarkoittaa ympäristöolosuhteista johtuvaa kuten veden puutteesta tai ravinteiden puutteesta johtuvaa stressiä (Jakson 1986, Tikka 2010). Bioottinen tarkoittaa elollisten taudinaiheuttajien aiheuttamaa esimerkiksi kasvitaudeista johtuvaa tai rikkakasvien aiheuttamaa stressiä (Jakson 1986). Stressi hidastaa kasvin fotosynteesiä ja aiheuttaa samalla muutoksia kasvin lehdiltä heijastuvan säteilyn voimakkuuteen (Jakson 1986, Tikka 2010). Kuva 6 on esitetty vastaavasti tulevan säteilyn heijastuminen nurmesta ja stressaantuneesta kasvusta aallonpituuden funktiona.




Kuva 6. Tulevan säteilyn heijastuminen nurmesta ja stressaantuneesta nurmesta aallonpituuden funktiona. X-akselina aallonpituus ja y-akselina heijastus. Muokattu lähteestä (Tucker 1979, Campbell ja Randolph 2011).

Kasvitaudit aiheuttavat lehtivihreäpitoisuuden vähenemistä spektrissä 550 nm; 650–720 nm kohdalla taudin alkuvaiheessa. Vastaavia muutoksia tapahtuu lähi-infrapuna-alueella (680–800 nm) ja keskipitkällä infrapunalla (1400–1600 nm) kohdalla (Franke ym. 2005). Jinua ym. (2018) tutkivat multispektrikameralla keltaruostetaudin leviämistä vehnällä ja havaitsivat, että tauti voidaan suurella todennäköisyydellä ($R^2=89$) havaita kasvustosta. Tulosten perustella ei kuitenkaan voi muiden kasvitautilien ja ympäristöstä johtuvien tekijöiden vaikutus täysin pois sulkea (Jinua ym. 2018). Kasvitaudin tai muun bioottisen tekijän steissistä kärsivien kasvien heijastus siirtyy terveen kasvin (Kuva 6) heijastuskäyrältä stressistä kärsivän kasvin heijastuskäyrälle. Heijastusten eroja vertaamalla voidaan steissistä kärsivät alueet erottaa kasvillisuuskartoissa terveistä alueista.

2.3.6 Lannoitus

Useat tutkimukset, Gitelson ym. (2003), Blackburn (2006), Hatfield ym. (2008), Campbell ja Randolph (2011), Thenkabail (2016a), ovat osoittaneet kasvien lehtivihreällä olevan voimakas yhteys typpilannoituksen määrään. Tutkimuksien mukaan vihreä (540–560

nm), red-edge (730–750 nm) ja lähi-infrapun (780–800 nm) aallonpituusalueiden heijastukset ovat herkimpiä typpilannoituksen vaihtelulle. Edellä mainittujen kasteiden leveys sekä sijainti spektrissä riippuvat tutkittavasta kasvista (Gitelson ym. 2003, Blacburn 2006, Hatfield ym. 2008, Campbell ja Randolph 2011, Thenkabail 2016a). Schlemmer ym. (2013) tutkivat maissilla viidellä lannoitustasolla lehtivihreän yhteyttä typpilannoitustasoon ja keksimääräiseksi regressioanalyysin selitysteeksi lehtivihreän määrään saatiin ($R^2 = 90$). Kuva 7 on esitetty lannoituksen vaikutus kasvin heijastusspektriin aallonpituuden funktiona.



Kuva 7. Lannoituksen vaikutus kasvien heijastukseen aallonpituuden funktiona.

Kuvassa maissin typpilannoitus 0 kg ja 150 kg. Muokattu lähteistä (Schlemmer ym. 2010, Grunzhauser ym. 2013).

Vertaamalla uusia ja vanhoja lohkolta otettuja kuvia voidaan havaita muutoksia kasvustossa ja näiden pohjalta luoda 3D ja 4D-malleja tietystä alueesta (Knipling 1970 ja Holopainen ym. 2015). 4D-malli tarkoittaa, että 3D-malliin lisätään aika eli kohdetta voi tarkastella eri aikakausina (Issa ym. 2005).

2.4 Kuvausolot Suomessa

Suomessa on viileä ja suhteellisen runsassateinen ilmasto, joka soveltuu hyvin nurmikasvien viljelyyn (Saukkonen 2008, Seppänen ym. 2008). Seppäsen ym. (2008) mukaan Suomessa viljellään nurmea jopa 30 % peltopinta-alasta. Ilmastollisista oloista johtuen taivas on usein pilviverhon peitossa (Saukkonen 2008). Thenkabailin (2016a) mukaan sääolot vaikuttaa kaukokartoitukseen, sillä satelliittikuvat eivät ole käyttökelpoisia, mikäli pilviä esiintyy taivaalla. Sama pätee myös korkealta pilviverhon yläpuolelta lentokoneesta otettujen kuviin. Uutena kaukokartoitusmenetelmänä voidaan pitää droneista otettuja kuvia, jotka onnistuvat pilvisestä säästä huolimatta johtuen lentokorkeudesta, joka on huomattavasti pilvien alapuolella (Thenkabailin 2016a). Sateisella sekä tuulisella säällä dronen lennätys yleensä onnistuu, sillä ensiksi dronet eivät kuluttajahintaluokassa ole vesitiiviitä ja toiseksi voimakas tuuli tekee lennosta epävakaa vaikeuttaen lentoreitillä pysymistä ja mahdollista kuvien ottamista (Elliott 2016). Tuulisella säällä lennättämisen rajat riippuvat käytettävästä dronen mallista (Baichtal 2015).

Kuvattavan kohteen valaistuksen vaihtelu johtuen esimerkiksi pilvisyyden vaihtelusta (Kuva 5) voi vääristää dronejen avulla otettuja kuvia, jos kuvauksessa ei käytetä valosensoria, joka säätää kameran asetuksia vallitsevan valaistuksen mukaan. Jos kuvan alueelle osuu pilven tai metsän muodostama varjo, jää karttoihin selvästi erottuva alue, joka hankaloittaa huomattavasti karttojen tulkintaa ja kuvien hyödyntämistä. Pilvien aiheuttamien varjojen vuoksi satelliittikuvista poistetaan pilvien lisäksi pilvien varoalueet eli myös aluetta pilvien ympäriltä (Zabala 2017, Elliott 2016 ja Thenkabailin 2016a). Zhu ym. (2018) tutkimuksessa etsittiin uutta menetelmään, jolla pilviset alueet voisi suodattaa kuvista pois. Tulosten perusteella, automaattisten seulontatapojen todettiin toimivan pilvisille alueille, mutta rajatapaukset eli pilvien reunat on vaikea seuloa pois (Zhu ym. 2018).

Pohjoisella pallonpuoliskolla aurinko ei paista suoraan ylhäältä päin kuten esimerkiksi päiväntasaajan ja kääntöpiirien alueella (Saukkonen 2008). Tämän vuoksi puun varjot (Kuva 5) aiheuttavat enemmän virhettä kuviin kuin päiväntasaajan alueella. Lisäksi kameraoptiikan on huomioitava kulma, jos kamerassa on valoa aistiva anturi (Zabala 2017).

2.5 Kasvustojen kuvaamisessa käytetyt kameratyypit

Tässä osiossa käydään läpi keskeisimmät ominaisuudet kameratyypeistä ja niiden eroista. Kameratyyppejä myös vertaillaan toisiinsa hankintahinnan suhteen sekä käydään läpi keskeisimpiä käyttökohteita.

2.5.1 Pankromaattinen kamera

Pankromaattinen kamera kuvaa laajaa aallonpituusaluetta yhtenäisenä kaistana. Kuvattava alueena on usein näkyvän valon aallonpituusalue (380–740 nm), mutta mukana voi olla myös kaistoja lähi-infrapuna-alueelta (700–1400 nm) riippuen kameran rakenteesta (Knipling 1970, Thenkabail 2016a). Pankromaattiset kamerat ovat kaikista yleisimpiä kameroita ja niitä käytetään esimerkiksi matkapuhelinten kameroina. Usein käytetään nimitystä RGB (Red-Green-Blue) kamera (Thenkabail 2016a).

2.5.2 Multi- ja superspektrikamera

Multispektrikamerassa on useita ennalta valittuja, kapeita aallonpituusalueita (kaistoja), jotka on erotettu toisistaan. Kun kyseessä on multi- tai superspektrikamera kaistan leveys tavallisesti 10–40 nm. Multispektrikamerassa on alle 10 aallonpituusaluetta ja superspektrikamerassa niitä on enemmän kuin 10. Jos aallonpituusalueiden määrä kasvaa yli 100:n, kutsutaan kameraa Hyperspektrikameraksi (Thenkabail 2016a). Multispektrikameroiden hinnat alkavat tällä hetkellä tuhansista euroista (Pix4D 2017a).

Multi- ja superspektrikameralla saadaan tutkittavasta kohteesta yksilöllisempää tietoa kuin pankromaattisella kameralla. Yksityiskohtien löytyminen kohteesta on erityisen tärkeää etenkin tutkimustyössä. Toisaalta multi- ja superspektrikameran spatiaalinen resoluutio on usein heikompi kuin pankromaattisen kameran (Thenkabail 2016a). Thenkabailin (2016a) mukaan tutkimustoiminta ja täsmäviljely ovat potentiaalisia multispektrikuvien käyttökohteita.

2.5.3 Hyper- ja ultraspektrikamera

Voimakkaasti kasvanut tutkimuskohde on viime aikoina ollut hyperspektrikameran käyttö luonnonvarojen hallinnassa (Thenkabailin 2016b). Hyper- ja ultraspektrikameroiden käytön yleistymistä rajoittaa tällä hetkellä kameroiden yli 100 000 euron hinta ja suuri fyysinen koko (Pix4D 2017a). Hyperspektri kamerassa on

yli 100 kaistaa, mutta kuitenkin alle 1000 kaistaa. Yli 1000 kaistan kameroista käytetään nimitystä ultraspektrikamera (Thenkabailin 2016a). Hyperspektrikamerassa kaistan leveys on tavallisesti 1 nm luokkaa ja käyttöalueena näkyvän valon sekä infrapunaa alueet (400–1 000 000 nm) (Thenkabailin 2016b).

Thenkabailin (2016a) mukaan hyperspektrikameralla saadaan erittäin tarkkaa tietoa kasvin fysiologisista ominaisuuksista. Kerättyä tietoa voidaan hyödyntää ja tehdä havaintoja liittyen kasvien terveydentilaan, lannoitustarpeeseen, tautitilanteeseen ja maaperän ominaisuuksiin sekä sadonmääritykseen (Thenkabailin 2016a ja 2016b).

Pöllönen ym. (2013) tutkimuksessa testattiin biomassan- ja typenmäärän määrittämistä ohra- ja vehnäkasvustosta droneen kiinnitettävällä hyperspektrikameralla. Kasvustoja lisälannoitettiin karttojen perusteella kesän aikana yhden kerran, johtuen lyhyestä kasvukaudesta. Tulosten perusteella todettiin lisälannoituksen olevan mahdollista kaukokartoituksen avulla sekä lannoituksen automatisointiin olevan hyvät edellytykset.

2.6 Kasvillisuusindeksit ja aallonpituudet

Kasvillisuusindeksillä tarkoitetaan paikkaan sidottua kasvillisuuden heijastusta tietyltä alueelta. Nimitystä kasvillisuusindeksi käytetään siinä tilanteessa, jos vähintään kaksi eri aallonpituusalueita (kaistaa) yhdistetään (Campbell ja Randolph 2011, Thenkabailin 2016b).

Thenkabailin (2016a) mukaan sinistä valoa (450–520 nm) käytetään mm. rannikkovesikartan laadinnassa, maaperän/kasvillisuuden erojen havaitsemisessa sekä lehti/havupuiden erottamiseen toisistaan. Vihreän valon (520–600 nm) spektriä tutkimalla voidaan havaita eroja kasvuston terveystilassa sekä kasvuston mahdollista stressiä (Thenkabailin 2016b). Vihreää valoa voidaan käyttää maaperän sekä kallioperän rautapitoisuuden määrittämisessä sekä raskasmetallien määrän havaitsemisessa kasvustossa (Chang ja Collins 1983).

Punaisen valon aallonpituusalueita (630–690 nm) hyödyntämällä voidaan tutkia lehtivihreän absorptiota ja erottaa kasvilajikkeita toisistaan (Thenkabail 2016b). Kasvuston biomassan määrittämiseen voidaan käyttää myös punaista aallonpituusalueita

(Tucker 1979). Thenkabailin (2016b) mukaan lähi-infrapunon spektriä voidaan käyttää kasvuston biomassan sekä vesipitoisuuden määrittämisessä.

Tucker (1979) tekemässä tutkimuksessa nurmella (Taulukko 1) arvioitiin punaisen, lähi-infrapunon ja vihreän valon heijastuksen vastaavuutta koeruudun biomassaan, lehtien vesipitoisuuteen ja lehtivihreäpitoisuuteen. Tutkimuksessa arvioitiin myös edellä mainituista heijastuksista lasketun lähi-infrapuna/punainen -suhteen eli kasvillisuusindeksin SR (Simple Ratio, kaava 1) ja TVI (Transformed Vegetation Index, kaava 2) vastaavuutta koeruudusta mitattaviin kasvin ominaisuuksiin. Tucker (1979) tutkimuksessa mittauksia tehtiin kesäkuussa ja lokakuussa, jotta saatiin kokonaiskuva, siitä miten kasvusto oli kehittynyt kasvukauden aikana. Tucker (1979) mukaan elossa olevien ja kuolleiden kasvien suhde on erilainen kasvukauden ulkopuolella. Mittauksessa käytetyt aallonpituusalueet olivat: punainen (630–690 nm), lähi-infrapuna (750–800 nm) ja vihreä (520–600 nm). Kaavojen 1 ja 2 laskuissa käytetään kameramallista riippuvaa aallonpituusaluetta, joka osuus esitetyn indeksin laskukaavan aallonpituusjakaumalle.

Taulukko 1. Tucker (1979) tekemän tutkimuksen tulokset tiivistettynä. Kesäkuun 1979 ja syyskuun 1979 eri aallonpituusalueiden heijastuman ja kasvustoindeksien regressioanalyysin selitysaste tuoreeseen ja kuivaan biomassaan nurmella.

Kaista	Tuore biomassa kesäkuu	Kuiva biomassa kesäkuu	Tuore biomassa syyskuu	Kuiva biomassa syyskuu
Punainen (R ²)	0,88	0,81	0,43	0,25
Lähi-infrapuna (R ²)	0,86	0,86	0,64	0,52
Vihreä (R ²)	0,79	0,72	0,22	0,14
Lähi- infrapuna/punainen (R ²)	0,86	0,75	0,34	0,16
SR (R ²)	0,81	0,73	0,34	0,16
TVI (R ²)	0,82	0,75	0,34	0,16

$$SR = \frac{NIR}{Red} \quad (1)$$

, jossa

NIR= lähi-infrapunon (700–1400 nm) pintaheijastuma (%)

Red= punaisen valon (600–700 nm) pintaheijastuma (%)

$$TVI = \sqrt{\frac{NIR-Red}{NIR+RED}} + 0,5 \quad (2)$$

, jossa

NIR= lähi-infrapun (700–1400 nm) pintaheijastuma (%)

Red= punaisen valon (600–700 nm) pintaheijastuma (%)

Tucker (1979) tutkimusta voidaan hyödyntää biomassan määrittämiseen. Käyttökelpoisimpia indeksejä ovat punaisen- ja lähi-infrapuna aallonpituusalueen heijastumat sekä näistä lasketut indeksit. Tuckerin (1979) tutkimuksen perusteella kasvukauden aikaiset havainnot (kesäkuu) kasvuston elinvoimaisuudesta ovat luotettavampia kuin kasvukauden ulkopuolella tehdyt havainnot (syyskuu). Syksyllä kasvustossa oli enemmän kuolleita kasveja ja näiden suuri osuus vaikutti kasvuston heijastukseen ja tulosten tarkkuus heikkeni.

Normalized Difference Vegetation Index (NDVI, kaava 3) mittaa yleisesti ottaen kasvuston terveyttä, elinvoimaisuutta ja sen määrää alueella (Rouse ym. 1973, Jensen 2005). Indeksi lasketaan lähi-infrapun ja punaisen valon suhteella, sillä näiden valojen suhde muuttuu kasvuston fysikaalisten ominaisuuksien muuttuessa (Davidson 2016). Kasvuston kärsiessä stressistä indeksin arvo laskee, kun punaisen valon heijastuksen voimakkuus kasvaa ja lähi-infrapun laskee. Vastaavasti, jos kasvusto on elinvoimaista alueella niin lähi-infrapun heijastus kasvaa ja punaisen valon laskee (Rouse ym. 1973, Jensen 2005, Davidson 2016).

$$NDVI = \frac{NIR-Red}{NIR+Red} \quad (3)$$

, jossa

NIR= lähi-infrapun (700–1400 nm) pintaheijastuma (%)

Red= punaisen valon (600–700 nm) pintaheijastuma (%)

Keskeinen ero Tucker (1979) esittämiin indekseihin VI ja TVI on, että NDVI indeksi saa arvoja väliltä -1 – 1 (Mroz ja Sobieraj 2004). Thenkabailin (2016b) mukaan indeksiiä voidaan käyttää lannoitustarpeen arvioinnissa sekä apuna biomassan määrittämisessä. Kuitenkin indeksin käyttäminen alueilla, jossa kasvusto on tiheää ja lehtialaa on runsaasti eli korkean lehtialaindeksin (LAI) alueille indeksi vaihtelee vähän ja luotettavaa kuvaan

kasvuston tilasta ei saada (Rouse ym. 1973). Kun kyseessä on vesi tai kivi Thenkabail (2016a ja 2016b) mukaan indeksi saa arvoja väliltä -1,0 – -0,5. Paljas maan pinta, lumi tai hiekka saavat indeksiarvoja 0,1 – 0,2 ja runsas kasvusto 0,2 – 1,0 (Thenkabailin 2016b).

Viljanen ym. (2018) tutkivat mm. biomassan määrittämisestä ja nurmen heijastuksen muutosta eri lannoitus tasoilla Yaran Kotkaniemen koeasemalla. NDVI -indeksillä selitettiin tutkimuksessa kuiva-ainesadosta keskimäärin $R^2=82$. Vastaavasti regressioanalyysin selitysaste tuoreeseen biomassaan oli 81 %. Koeaseman tutkimuksessa testattiin koeruuduilla 0–150 kg typpilannoitusta. Heikoin regressioanalyysin selitysaste oli kuivaan biomassaa 74 % (0 kg/ha -typpikaista) ja paras 95 % (50 ja 100 kg/ha typpikaistoilla). Märkään biomassaan verrattaessa heikoin 73 % (0 kg/ha -typpikaista) ja paras 96 % (125 kg/ha typpikaista).

Cho ym. (2007) tutkivat biomassan määrittämistä hyperspektrikameralla Majella kansallispuistossa Italiassa nurmi- ja yrttikasveilla. Kansallispuiston alueella tyypillisiä nurmilajikkeita olivat: (*Rachypodium genuense*, *Briza media*, *Bromus erectus* ja *Festuca* sp). Tutkimuksessa käytettiin useita kaistoja NDVI -indeksin laskennassa ja paras selitysaste ($R^2=70$) kuivaan biomassaan saatiin kaistoilla 771 nm ja 740 nm.

Mutangan & Skidmore (2002) tutkivat laidunalueella biomassan määrittämistä. Regressioanalyysin selitysaste NDVI -indeksillä oli 80 %, lähi-infrapuna/punainen valon -suhteella 77 % ja TVI -indeksillä 77 %. Laidunalueella pääasiallinen nurmikasvi oli *Cenchrus ciliaris* ruoho. Mutangan ja Skidmoren (2002) tutkimuksessa todettiin indeksien laskennassa käytetyn aallonpituusalueen kaistan leveyden oleellisesti vaikuttavan selitysasteisiin.

Enhanced Vegetation Index (EVI, kaava 4) eli parannettu kasvillisuusindeksi huomio laskukaavassa taustan vaikutuksen, huomioi satelliittikuvista ilmakehän häiriöitä sekä soveltuu käytettäväksi korkean biomassan alueilla (Huete ym. 1994, Huete ym. 1997). Indeksillä on kehitetty NDVI-indeksistä ja sen fysikaaliset perustat ovat samoja (Huete ym. 1994, Huete ym. 1997, Hueten ym. 2002). Laskukaava myös antaa mahdollisuuden syöttää korjauskertoimia eri ominaisuuksien korostamiseksi. Kertoimia $C1=6$ ja $C2=7,5$ käytetään ilmakehän aerosolien heijastuksen vaikutuksen kumoamiseksi (Huete ym.

1997). Kerrointa $L=1$ eli taustan heijastuksen säätökerrointa käytetään taustan erottamiseksi syntyvästä indeksikartasta (Huete ym. 1994, Huete ym. 1997).

$$EVI = 2,5 \times \frac{NIR - Red}{(NIR + C1 \times Red - C2 \times Blue + L)} \quad (4)$$

,jossa

NIR=lähi-infrapun (700–1400 nm) pintaheijastuma (%)

Red=punaisen valon (600–700 nm) pintaheijastuma (%)

Blue=sinisen valon (400–500 nm) pintaheijastuma (%)

C1= ilmakehän aerosoliresistenssin kerroin

C2= ilmakehän aerosoliresistenssin kerroin

L= taustan heijastuksen säätökerroin

EVI ja NDVI indeksejä vertaillen havaitaan molempien indeksien kuvaavan kasvien elinvoimaisuutta, määrää sekä terveyttä alueella (Huete ym. 1994, Huete ym. 1997, Thenkabailin 2016b). Alueilla, jossa maanpintaa on enemmän paljaana, EVI-indeksi antaa tarkemman kuvan todellisuudesta (Huete ym. 2002). Huete ym. (2002) mukaan suuren lehtialaindeksin (LAI) alueilla EVI indeksi toimii NDVI indeksiä tarkemmin. Indeksejä vertaillen Matsushitan ym. (2007) tutkimuksessa havaittiin EVI indeksin olevan NDVI indeksiä herkempi topografian muutokselle kuvattavalla alueella. Tulosten perusteella Matsushitan ym. (2007) suositteli kaikille indeksikartoille kuvan oikaisua topografian suhteen ennen niiden vertailua.

Leaf Area Index (LAI, kaava 5) eli lehtialaindeksi kuvaa kasvuston lehtien pinta-alan suhdetta sen peittämään maan pinta-alaan (Seppänen ym. 2008, Thenkabailin 2015a). Jos indeksi saa arvon 1, niin kasvusto lehtien pinta-ala riittää peittämään maan pinta-alan kokonaan (Boeght ym. 2002). Lehtialaindeksi tai yksittäisen kasvin lehtiala ei kuitenkaan huomio sitä, että kasvustossa osa lehdistä peittää kokonaan tai osittain toisensa (Seppänen ym. 2008). Alempien lehtien vastaanottaman säteilyn määrä jää huomattavasti pienemmäksi kuin ylimpien. Lehtiala indeksiä voidaan käyttää lehtialan kasvun mittaamiseen sekä biomassan määrän määrittämiseen (Boeght ym. 2002).

$$LAI = \frac{LA}{P} \quad (5)$$

, jossa

LA= lehtien ala (m²)

P= maan ala (m²)

Viljelykasveille on laskettu optimaalinen lehtialaindeksi eri maapallon alueille. Pystykasvuilla nurmiheinillä säteilyn hyväksikäytön kannalta optimaalinen lehtialaindeksi on 5–7 ja vastaavasti nurmipalkokasveilla 3–4 (Seppänen ym. 2008). Hunt ym. (2010) tutkivat vehnällä biomassan ja lehtialaindeksin vastaavuutta. Tutkimuksessa saatiin regressioanalyysin selitysteeksi 79 %.

Mutangan & Skidmore (2002) mukaan suurilla LAI arviolla biomassan määrittäminen kaukokartoituksen avulla sekä tarkan LAI:n määrittäminen on haasteellista niin sanotusta kylläisyysongelmasta johtuen. Kylläisyysongelma johtuu siitä, että kasvin lehdet ovat päällekkäin ja alimmaisten lehtien heijastus läpäisee rajoitetusti yläpuolella olevat lehtikerrokset. Liika biomassa vääristää mittaustuloksia, sillä kasvin heijastus ei muutu lineaarisesti biomassan muuttuessa (Mutanga ja Skidmore 2002).

Normalized Difference Red Edge Index (NDRE, kaava 6) kertoo kasvuston lehtivihreäpitoisuudesta, abioottisesta ja bioottisesta stressiä, typen hyväksikäytöstä ja kasvien elinvoimaisuutta (Gitelson ym. 1994, Thenkabailin 2015b). NDVI-indeksin poiketen NDRE-indeksi ottaa laskukaavassa lähi-infrapunan sijaan huomioon Red Edge kaistan (712–723 nm), joka on muun muassa herkkä alue typpilannoitustasovaihtelulle (Mroz ja Sobieraj 2004, Novona 2013). Lehtivihreäpitoisuudella on suuri korrelaatio kasvuston typpitasoon, joten indeksiä voidaan käyttää täsmäviljelyssä mm. lannoitustarpeen arvioimiseen (Thenkabailin 2016b).

$$NDRE = \frac{NIR - Red\ Edge}{NIR + Red\ Edge} \quad (6)$$

,jossa

NIR=lähi-infrapun (700–1400 nm) pintaheijastuma (%)

Red Edge = red edgen (712–723 nm) pintaheijastuma (%)

Gitelson ym. (1994) tutkivat lehtivihreän määrittämistä NDRE indeksillä *Aesculus Hippocastunum* L. ja *Acer Platanoides* L. kasvien lehdillä. Regressioanalyysin selityssasteeksi saatiin lehtivihreän ja typpipitoisuuden välille 97 %.

Kirjallisuuden perusteella pelkän karttapohjaisen tarkastelun pohjalta on vaikea tehdä johtopäätöstä kasvuston tilasta, sillä sama heijastus voi johtua mm. rikkakasvien runsaasta määrästä eikä välttämättä rehevästä kasvustosta (Campbell ja Randolph 2011). Indeksikarttojen selitys kasvuston tilasta riippuu mm. kasvustolajista, kasvuston tiheydestä, maaperän ominaisuuksista ja kuvausajankohdasta eli onko kuvaus tehty kasvukaudella vai kasvukauden ulkopuolella (Mroz ja Sobieraj 2004, Thenkabailin 2016a/b).

3. TUTKIMUKSEN TAVOITTEET

Tässä tutkimuksessa selvitettiin, miten droneen kiinnitettävällä multispektrikameralla voitiin havainnoida nurmikasvustoja ja määrittää kasvuston biomassa. Tutkimuksen tulokset kerättiin kuvaamalla yhtä nurmilohkoa Viikissä ennen ensimmäistä ja toista niittoa sekä yhtä lohkoa Töysässä ennen ensimmäistä niittoa. Lentojen aikana kerätyt kuvat yhdistettiin ortomosaiikeiksi, joiden pohjalta lohkolta määritettiin sijainnit vertailutiedon keräämistä varten. Vertailutietoa kerättiin mittaamalla kasvustosta pituus, lehtialaindeksi ja lehtivihreäpitoisuus sekä keräämällä korjuuaikanäyte.

Droneihin kiinnitettävän multispektrikameran käyttö kasvustojen tarkkailussa on vielä suhteellisen uusi innovaatio ja sen käytöstä kotimaisissa oloissa on hyvin vähän tieteellistä tietoa saatavilla. Tämän tutkimuksen tavoitteena oli osaltaan kerätä lisää tietoa ensinnäkin dronen ja kamerayhdistelmän käytöstä kotimaisissa oloissa sekä kartoittaa tähän liittyviä haasteita ja mahdollisuuksia.

Tutkimuksen ensisijainen tavoite oli selvittää, miten nurmen biomassaa voidaan määrittää käyttäen apuna dronen ja multispektrikameran yhdistelmää. Tutkittavana kaistana oli lähi-infrapuna sekä normalisoitu kasvillisuusindeksi (NDVI) -kartta. Tavoitteena oli myös multispektrikameran sovittaminen kaupalliseen droneen niin, että laitteistoa voitaisiin käyttää pelto oloissa. Kerätyistä kuva-aineistoista käytettiin kaikkia multispektrikameran tuottamia aallonpituusalueita ja kirjallisuuden perusteella kerätystä aineistosta laskettiin NDVI, EVI ja NDRE kartat.

Tutkimushypoteesit olivat:

- Lähi-infrapunakartan (NIR-kartta) ja Normalisoidun kasvillisuusindeksikartan (NDVI -kartan) soveltuvuus satokartaksi nurmikasvustossa.
- Dronen soveltuvuus lisähavainnointivälineeksi nurmikasvustokäynnin yhteydessä.

4 AINEISTO JA MENETELMÄT

Tässä osiossa käydään läpi tutkimuksessa käytettyjen lohkojen perustiedot, kuvien käsittelyyn käytetyn Pix4D -ohjelman toimintaperiaatteet, aineiston keräämisen käytettävien mittalaitteiden tekniset ominaisuudet ja sitä, miten automaattisia lentotehtäviä lennettiin lohkoilla. Lisäksi käydään läpi pikselien arvon määrittäminen kuvista.

4.1 Koelohkot ja niiden viljely

Tutkimusta varten perustettiin kenttäkoe Koirasuo -nimiselle koelohkolle (Liite 1) Viikissä (sijainti ETR89 -järjestelmässä 60°12 ' lat., 25° 01 ' lon) ja Isokyrö -nimiselle koelohkolle (Liite 2) Töysässä (sijainti 62° 41 ' lat., 23° 53 lon), jotta drone – multispektrikameraa voitiin testata viljelyoloissa. Koirasuon koelohko jaettiin kahdeksi osaksi kuvauskorkeudella kulkevan voimalinjan vuoksi. A-osan eli tilakeskuksen puolella olevan lohkon pinta-ala oli 7 ha ja B-osan eli Herttoniemen puolella olevan koelohkon osa noin 3,5 ha. Töysässä oleva Isokyrö -niminen koelohko on noin 6 ha suuruinen.

Molemmilla koelohkoilla oli neljännen vuoden timotei (*Phleum pratense*) – nurminata (*Festuca pratensis*) nurmikasvusto ja lohkot olivat salaojitettuja. Koirasuon salaojakartta on esitetty (Liite 3). Isokyrön salaojakarttaa ei ollut saatavilla. Lohkot lannoitettiin tavanomaisesti ja lisäksi Isokyrö lohkolle testattiin myös 0-typipitasokaistan vaikutusta kasvustokuvuihin. Alun perin oli tarkoitus kerätä havaintoja sekä ensimmäiseltä että toiselta sadolta molemmilta esitellyiltä koelohkoilta. Dronen, siihen liittyvän multispektrikamerajärjestelmän yhteensovittamisen ja kuvausteknisten haasteiden vuoksi, ensimmäiselle sadolle kuvattiin Isokyrö ja Koirasuon B-osa kertaalleen ja toiselle sadolle Koirasuo kokonaisuudessaan, mutta ei Isokyrö -lohkoa.

Lohkokirjanpidon mukaan keväällä 2017 Koirasuon -koelohkolta torjuttiin voikukkaa Primus -kasvinsuojeluaineella (0,1 l/ha) + Sito plus (0,1 l/ha) kiinnikkeellä. Isokyrö lohkolle ei tehty kasvinsuojelutoimenpiteitä kasvukauden 2017 aikana. Koirasuo lohkolle levitettiin ensimmäiselle sadolle 20.4.2017 Belor Premium Typpi 27-0-0-4 (N-P-K-S) väkilannoitetta 264 kg/ha ja toiselle sadolle 15.6.2017 Yaran Can27 + Mg 27-0-0 väkilannoitetta 250 kg/ha. Isokyrö lohkolle levitettiin Belor Premium typpi 27-0-0+Se 360 kg/ha ensimmäiselle sadolle.

4.2 Kuvausdrone ja multispektrikamera

Nurmikasvustojen kuvaukseen käytettiin kaupallista 3DR Solo -nelikopteria, jonka ohjelmisto perustui vapaaseen lähdekoodiin (Taulukko 2). Kopterin kamerana käytettiin kaupallista RedEdge –multispektrikameraa (Taulukko 3). Multispektrikameralle rakennettiin droneen 2-akselinen vakain (Kuva 2), joka pitää kameran kohtisuorassa maanpintaan nähden riippumatta dronen asennosta. Automaattisena lento-ohjelmana käytettiin kaupallista Pix4D Capture V3.0.1 beta -versiota (Pix4D 2017a). Beta -version haasteena oli, että se tuki ainoastaan neliön tai suorakulmion muotoisten lentotehtävien suunnittelua ja lentämistä. Avoimeen lähdekoodiin perustuvaa automaattista Tower -nimistä ohjelmaa testattiin myös, mutta toistuvien yhteysongelmien vuoksi sen käytöstä luovuttiin (User Manual 3D Solo 2017).

Taulukko 2. 3DR Solo -nelikopterin tekniset ominaisuudet (User Manual 3D Solo 2017).

Ominaisuus	Arvo	Yksikkö
Akku	5200	mAh
Propellit	4,5	Tuumaa
Lentoaika (ilman kameraa)	25	min
Lentoaika (RedEdge kameran kanssa)	6	min
Paino (ilman kameraa)	1,5	kg
Paino (RedEdge kameran kanssa)	2,3	kg
Akun jännite	14,8	V
Mitat (moottorilta moottorille)	25 ja 46	cm
Suurin lentonopeus	89	km/h
Suurin lentokorkeus	122	m

Taulukko 3. RedEdge multispektrikameran aallonpituusalueet, kaistojen- keskikohdat ja pituudet (Micasense 2015).

Kaistan numero	Nimi	Kaistan keskikohta (nm)	Kaistan pituus (nm)
1	Sininen	475	20
2	Vihreä	560	20
3	Punainen	668	10
4	Lähi-infrapuna	840	40
5	Red Edge	717	10

RedEdge -kamera ottaa samanaikaisesti kuvan viideltä eri aallonpituusalueelta kuvan: punainen, sininen, vihreä, red edge ja lähi-infrapuna. Kamera mittaa kultakin

aallonpituusalueelta kasvustosta heijastuvaa sähkömagneettisen säteilyn määrää. Kamera tallentaa raakakuvat joko TIFF (16-bit) tai PNG (12-bit) muotoon. Tässä tutkimuksessa kuvat tallennettiin TIFF (16-bit) muotoon. RedEdge -kameran yhteydessä käytettiin automaattista kameran kirkkauden säätövalosensoria Downwelling Light Sensor (DLS), joka sijoitettiin dronen yläpuolelle. Kameraan kiinnitettiin myös GPS-vastaanotin, joka tallensi jokaiseen kuvaan GPS koordinaatin (Pix4D 2017a ja Pix4D 2017b).

4.3 Lohkojen kuvaukset

Lohkojen kuvaamiseen varattiin runsaasti aikaa sekä kuvaukset pyrittiin tekemään keskipäivällä parhaaseen mahdolliseen aikaan, jolloin aurinko paistoi mahdollisimman kohtisuoraan. Kirjallisuuden perusteella keskipäivää suositeltiin käytettäväksi kuvausajankohtana (Thenkabailin 2016a/b, Pix4D 2017a). Taulukko 4 on esitetty lentojen ajankohdat sekä kuvauslentoihin liittyvät tarkemmat tiedot.


Taulukko 4. Kuvausajankohdat ja kuvauslentoihin liittyvät tekniset tiedot

Päivä ja klo aika	Nimi	Lento-korkeus (m)	Tuuli (m/s)	Kuvanotto-taajuus (Hz)	Lento-nopeus (m/s)	Sää
6.6.2017 klo 11	Koira-suo B	50	0–2	0,8	5	Puoli-pilvinen
9.6.2017 klo 17	Iso-kytö	50	0–2	1,0	5	Pilvinen
12.7.2017 klo 12	Koira-suo A	50	1	0,8	3–4	Pilvinen

Isokyrön kuvauksessa lentoja tehtiin kaiken kaikkiaan kolme kappaletta ja kunkin lennon kuvat yhdistettiin yhtenäiseksi kartaksi. Vastaavasti Koirasuon A-osan kohdalla lentoja tehtiin kuusi kappaletta ja Koirasuon B-osan kohdalla kaksi kappaletta. Koirasuon A-osan kuvauslennoissa lentosuuntana käytettiin sekä itä-länsisuuntaa että pohjois-eteläsuuntaa pellon muodosta johtuen. Isokyrön kuvauksessa käytettiin lentosuuntana länsi-itäsuunta ja Koirasuon B-osan kohdalle Itä-länsi ja luode-kaakko -suuntia.

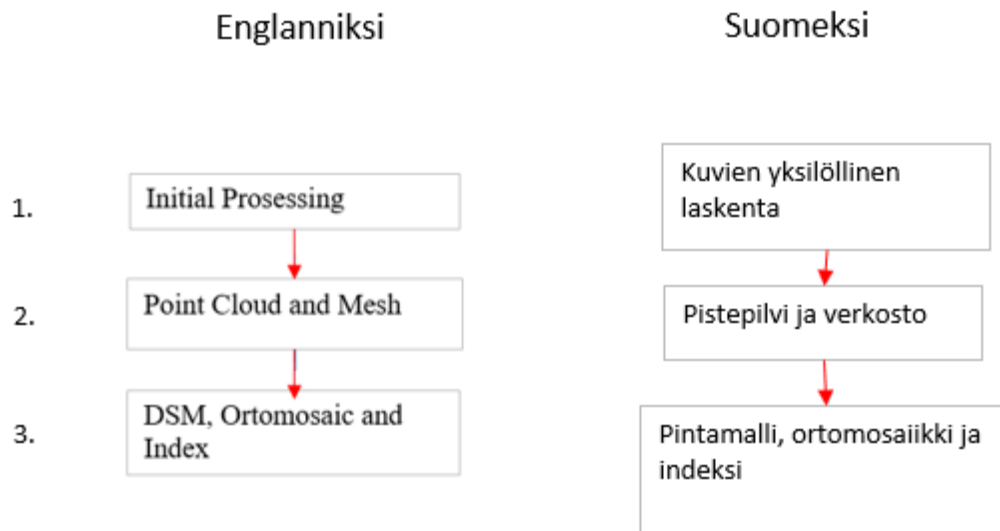
4.4 Lentotehtävät ja kuvien käsittely

Automaattisissa lentotehtävissä käytettiin vähintään 80 % peittoa (otettavat kuvat 80 % päällekkäin etenemis- ja sivusuunnassa, Kuva 8), joka ylitti ortomosaiikin laskennan vaatimuksen 75 % peitosta etenemis- ja sivusuunnassa (Micasense 2015). Toiselle sadolle käytettiin 95 % peittoa ja hidasta 3 m/s tavoitteellista lentonopeutta, jotta tutkimuksen aikana havaittu DLS anturista johtuvan virheen vaikutus saataisiin mahdollisimman vähäiseksi indeksikarttoihin. Raakakuvista poistettiin ennen kuvien yhdistämistä kuvausalueen ulkopuolella olevat kuvat, päällekkäiset kuvat, nousun ja laskun aikana eri kuvauskorkeudesta otetut kuvat kuvien yhdistämiseen käytettävän laskenta-ajan lyhentämiseksi.



Kuva 8. Peräkkäisten kuvien peitto.

Kuvat yhdistettiin Pix4Dmapper -ohjelman 3.3.29 työpöytäversiolla. Ohjelman kuvien käsittelykaavio on esitetty Kuva 9. Kuvien yhdistämisessä käytettiin apuna WGS84 -koodinaattitasojärjestelmää, joka oli ohjelman oletusasetus. Pix4Dmapper -ohjelma tunnisti kameratyyppin automaattisesti, joten kameran teknisiä ominaisuuksia ei tarvinnut erikseen määrittää laskentaa varten (Pix4D 2017a ja Pix4D 2017b).



Kuva 9. Pix4D ohjelman kuvien käsittelykaavio englanniksi ja suomeksi. Lyhyesti selitettynä ohjelma aluksi korjaa tai hylkää kuvien vääristyneet alueet. Laatii tason pinnasta pistepilven sekä laskee uudestaan tason pinnasta kameran sijainnin. Lopuksi kuvastusta alueesta syntyy pintamalli, kameran aallonpituusalueista (kaistoista) heijastuskartta sekä kameran kaistoja yhdistämällä ohjelma laskee kasvillisuusindeksejä (Pix4D 2017b).

Prosessoinnin ensimmäisessä vaiheessa (Initial Prossessing) tehdään kuvien yksilöllinen laskenta. Kuvien joukosta poimitaan virheettömät alueet ja kuvat yhdistetään yhtenäiseksi ortomosaikiksi. Laskentavaiheen lopuksi saadaan laaturaportti, jossa on tarkasteltavissa mm. matalan resoluution pintamalli ja ortomosaikkikartta (mittatarkka ilmakeku), kuvausalueen peitto, keskimääräinen viereisiin kuviin yhdistettyjen pisteiden määrä kuvaa kohden, hylättyjen kuvien määrä kpl ja hylättyjen kuvien alueiden osuus (Pix4D 2017a, Pix4D 2017b.)

Prosessoinnin toisessa vaiheessa lasketaan pistepilvi ja 3d tekstuuri malli (Point Cloud and 3d Textured Mesh). Pistepilvi tarkoittaa jokaisen kuvasta lähtevän säteen heijastuspisteen pistettä. Jokaiselle pisteelle määritetään valitun koordinaattitasojärjestelmän (WG84) apua käyttäen x-, y- ja z-koodinaatit. (Pix4D 2017a, Pix4D 2017b.) Kameran raakakuvien GPS koordinaattien tarkkuus on muutamia metrejä, joten tässä laskennan vaiheessa niiden GPS -koordinaatti korjataan vastaamaan todellista, laskemalla kameran pistepilven x-, y, ja z- koodinaatteja apuna käyttäen korjattu kameran

sijainti (Poutanen 1999). 3d tekstuuri malli tarkoittaa vastaavasti pistepilven pisteiden tason pinnan määrittämistä eli luodaan kuvatusta alueesta kolmiulotteinen malli (Pix4D 2017a, Pix4D 2017b).

Prosessoinnin kolmannessa vaiheessa käytetään kohinasuodatusta (DSM, Digital Surface Model Filters) ja pistepilven virheelliset (kohinasta johtuvat) pinnan muodon koordinaattipisteet korjataan (Pix4D 2017a). Laskennassa käytettiin 7x7 pikseliä maskin kokona ja Noise -Filt asetusta eli mediaanisuodatusta (Pix4D 2017b), joka korjaa suuret korkeusvaihtelusta johtuvat erot viereisten pisteiden välillä. Suodattimen käyttö voi aiheuttaa alueita, joissa on virheellisiä pieniä notkelmia. Kuoppien tasoittamiseksi käytettiin toista suodatinta eli Surface Smoothin asetusta Sharp, joka oli ohjelman oletussuodatus. Sharp asetusta tasoittaa muodon pinnan, mutta säilyttää pintaan kuuluvat suuret terävät muodot kuten rakennusten reunukset (Pix4D 2017a, Pix4D 2017b).

Tulosten suodattamisen jälkeen syntynyt ortomosaiikki tallennettiin GeoTiff -tiedostona käyttäen laskenta-algoritmia Inverse Distance Weighting, (käänteinen etäisyyspainotus), joka interpoloi pistepilven pisteiden välisen etäisyyden (Pix4D 2017a ja Pix4D 2017b). Tallennuksessa käytettiin Merge Tiles -vaihtoehtoa eli pikseleille annettiin arvo ja määritettiin tallennettavan ortomosaiikin resoluution tarkkuus, jossa käytettiin tarkinta mahdollista vaihtoehtoa. Jokaiselle lentokerralle oli eri tarkkuus, johon vaikuttivat mm. lentokorkeus sekä kameran ominaisuudet.

Spatiaalisen interpoloinnin tarkoituksena oli käyttää pinnan laskemisessa mitattuja arvoja ja ennustaa näiden välissä oleville alueille pisteiden arvot (Holopainen ym. 2015). Interpoloinnissa kuvaamalla mitatun pinnan pisteitä luotiin GeoTiff-tiedostoon arvot tasavälein (pohjoinen-etelä, itä-länsi suunnissa).

Kuvauslennon alussa kameralla otettiin kuva heijastuslevystä. Heijastuslevystä otetuilla kuvilla tehtiin radiometrinen optimointi kameran jokaiselle kaistalle vasten tunnettua heijastavaa pintaa ennen indeksikartan laskentaa. Radiometrinen optimointi tarkoittaa karttojen kykyä havaita säteilyeroja toistettavasti vaihtelevissa valaistusoloissa (Holopainen ym. 2015). Radiometrisen optimoinnin avulla pyrittiin parantamaan kuvan heijastusarvojen todenmukaisuutta ottamalla huomioon kuvien kussakin oloissa vallitseva valaistustaso sekä kameran rakenteelliset ominaisuudet (Pix4D 2017a ja Pix4D 2017b).

Ennen indeksikartan laskemista heijastuskartoista rajattiin ulkopuolelle lohkon ulkopuoliset alueet sekä puiden varjoista johtuneet virheet. Indeksikarttalaskennassa heijastuskartan heijastusarvot määritettiin uudelleen käyttämällä tiettyä aallonpituusaluetta tai yhdistämällä eri aallonpituusalueita. Laskennassa käytettiin tiettyjä ennalta määritettyjä värityssääntöjä kuten RGB -arvoja sisältävät rasteri tiedostojä. Indeksikartat jaettiin viiteen yhtä suureen alueeseen pintaa-alan perusteella pikseleiden arvon perusteella (Pix4D 2017a ja Pix4D 2017b).

Laskennan lopussa kameran kaistojen heijastuskartoista laskentaan kasvillisuusindeksikarttoja käyttämällä haluttua laskukaavaa esimerkiksi NDVI, EVI ja NDRE indeksien laskennassa (Pix4D 2017a ja Pix4D 2017b). Heijastuskarttoja ohjelman avulla voi muuttaa visuaalisesti helpommin tulkittavaksi normalisoimalla kuva eli muuttamalla heijastuskuva värikuvaksi (Thenkabailin 2016a/b). Tässä tutkimuksessa lähi-infrapunakartta muutettiin punaisen värin väriavaruuteen (yksi ulottuvuus tyhjänä) ja muut indeksikartat RdYlGn-väriavaruuteen. Lopuksi indeksikartat tallennettiin GeoTIFF-muotoon ja karttoihin liitettiin havaintotunnukset, mittakaava ja pohjoissuunta (Pix4D 2017a ja Pix4D 2017b).

4.5 Referenssinäytteet

Koelohkoilta kerättiin kuvaamisen yhteydessä referenssinäytteitä multispektrikamerakuvien kalibrointiin. Suurin osa havainnointikohdista valittiin ilmakuvan perusteella; pyrkimyksenä oli saada mahdollisimman kattava kuva koelohkon eri osista. Referenssinäytteiden ottokohdat määritettiin kunkin kuvauksen jälkeen uudelleen riippumatta edellisestä kuvauksesta. Tästä olivat poikkeuksena Koirasuon toisen sadon kuvaukset, joissa kuvauksen havainnot kerättiin samoista kohdista lohkoa kuin ensimmäisessä kuvauksessa.

Havainnoiduilta lohkoilta ei kerätty kaikista kohdista samoja näytteistä, havaintojen luonteen vuoksi sekä mittausteknisistä syistä. Kasvustokäynnin yhteydessä ilmeni havaintoja, joita ei ilmakuvan perusteella osattu määrittää. Koirasuon B -osalta kerääntyi yhteensä 13 havaintoa, Isokyröltä 13 ja Koirasuo A -osalta 11. Referenssihavaintojen kohdat on merkitty Koirasuon B-osan karttaan B -symbolilla, Isokyrön karttaan K -symbolilla ja Koirasuo A-osan karttoihin D -symbolilla.

4.6 Lehtialaindeksi-, lehtivihreä- ja biomassamittaukset

Lehtialaindeksihavainnot kerättiin Decagon AccuPAR LP-80 PAR/LAI mittarilla timotein kalibrointiasetuksilla (Taulukko 5). Yhdestä havaintokohdasta mitattiin 10 lehtialaindeksihavaintoa, joiden keskiarvoa käytettiin lopullisissa tuloksissa. Kaikista lohkolta kerätyistä havaintokohdista laskettiin keskiarvo ja keskiarvon keskivirhe. Tuloksia verrattiin lohkolta samasta kohdasta kerättyihin biomassahavaintoihin. Lehtialaindeksihavainnot kerättiin Koirasuon B -osan lohkolta seitsemästä, Isokyrön lohkolta viidestä ja Koirasuon A-osan kuudesta eri havaintokohdasta.

Taulukko 5. Lehtialaindeksin mittaamiseen käytetyn Decagon AccuPAR LP-80 PAR/LAI -mittarin tekniset tiedot valmistajan mukaan (Decagon Devices inc. 2017).

Ominaisuus	LP-80	Yksikkö
Käyttöalue	0 – 50	°C
Antureiden määrä	80	kpl
PAR -vaihteluväli	0 > 2500	μmol/m ² s
Resoluutio	1	μmol/m ² s
Mittalaitteen pituus	80	cm

Lehtien lehtivihreän määrä mitattiin Apogeen Chlorophyll Concentration Meter Model MC-100 -mittarilla (Taulukko 6). Kalibrointiasetuksena käytettiin yleistä asteikkoa, sillä laitteessa ei ole omaa kalibrointiasteikkoa nurmikasveille. Lehtivihreän määrää mitattiin samoista havaintokohdista kuin lehtialaindeksitkin. Jokaisesta havaintokohdasta tallennettiin 10 mittaustulosta sattumanvaraisesti eri nurmikasveista. Nurmikasvin valintaa rajoitti laitteen mittaavan osan suuri koko. Sen vuoksi voitiin mitata vain suurilehtisten nurmikasvien lehtivihreän määrää. Lehtivihreähavainnot kerättiin Koirasuon B-osalta seitsemästä, Isokyrön lohkolta viidestä ja Koirasuon A -osan lohkolta kuudesta havaintokohdasta.

Taulukko 6. Lehtivihreä mittaukseen käytetyn Apogeen Chlorophyll Concentration Meter Model MC-100 -mittarin tekniset tiedot valmistajan mukaan (Apogee Devices Inc. 2017).

Ominaisuus	MC-100	Yksikkö
Käyttöalue	0 – 50	°C

Mittaava alue	63,6	mm ²
Resoluutio	+/-10	µmol/m ²
Mittausalue	653 – 931	nm
Tulosten lineaarisuus	1	%
Tulosten toistettavuus	1	%

Mittaustuloksista hylättiin ennen käsittelyä merkittävästi havaintojen keskiarvosta poikkeavat tulokset. Mittaustulokset, jotka poikkesivat keskiarvosta yli 100 µmol/m² hylättiin, koska satunnaisesti laite rekisteröi tuloksia itseksensä mittauksen aikana. Jäljelle jääneistä tuloksista laskettiin keskiarvo ja keskiarvon keskivirhe. Tuloksia verrattiin lohkolta samasta kohdasta kerättyihin biomassahavaintoihin.

Korjuuaikanäytteiden ottokohdat määritettiin lähi-infrakuvakartan perusteella. Jokainen näyte koostui neljästä osanäytteestä. Kunkin osanäytteen pinta-ala oli 0,25 m². Näytteiden keräämisen yhteydessä mitattiin nurmikasvien keskimääräinen pituus rullamitalla kustakin osanäytteen ruudussa. Osanäytteen mittauskohdissa arvioitiin silmämääräisesti kasvustontiheys kyseisellä kohtaa. Mittauskohdista sekä lohkon eri osista kerättiin yleis- ja kasvustohavaintoja ilmakuviin tueksi. Raakanäytteet punnittiin Mettler Toledo PM 4600 vaa’alla Koetilantie 5:n laboratoriossa ja niistä otettiin edustava 2 litran näyte lähetettäväksi Valion laboratorioon tarkempia määrittelyjä varten (Taulukko 7). Valion laboratoriossa tätä tutkimusta varten määritettiin biomassan kuiva-aine.

Taulukko 7. Punnitukseen käytetyn Mashall Mettler Toledo PM 4600 -vaa’an tekniset tiedot (Mashall Devices Inc. 2017).

Ominaisuudet	PM 4600		Yksikkö
Kapasiteetti	4100		g
Punnitusalueet	600	4100	g
Tarkkuus	0,01	0,1	g
Toistettavuus	0,01	0,03	g

Korjuuaikanäytetulokset analysoitiin Valion laboratoriossa Seinäjoella. Näytteistä määritettiin kuiva-ainepitoisuus, D-arvo eli sulavan orgaanisen aineen määrä kuiva-aineessa, raakavalkuainen, NDF kuitu (Neutral Detergent Fiber), sokeripitoisuus, iNDF kuitu (Inergent Neutral Detergent Fiber), tuhkapitoisuus, ME (muuntokelpoinen energia), OIV ohutsuolivalkuainen ja PVT eli pötsin valkuaistase. Korjuuaikanäytteestä määritettyä biomassaa (kuiva-aine) sekä D-arvoa käytettiin tässä työssä ja muut laboratorion tulokset jätettiin tässä työssä rajauksen johdosta käsittelemättä tarkemmin.

4.7 Pikseleiden arvojen määrittäminen

Kaikista Red edge -kameran kaistoista määritettiin korjuuaikanäytteen keräyskohdista heijastuspikselin keskimääräinen arvo ja keskiarvon keskivirhe. Arvo määritettiin 50x50 pikselin alueelta GPS koordinaatteja apuna käyttäen. Heijastusarvoista laskettiin kasvillisuusindeksejä NDVI, NDRE ja EVI. Arvojen laskennassa käytettiin Matlab-ohjelmaa.

4.8 Tulosten tarkempi rajaaminen

Tutkimustuloksia rajattiin siten, että käsiteltäväksi otettiin Koirasuon B-osan kuvaus ja Isokyrön kuvaus ensimmäiselle sadolle. Toisen sadon kuvauksista otettiin mukaan vain Koirasuon A-osan kuvas aineiston suuren määrän vuoksi. Kaikki kuvauskerrat, jossa oli DLS -anturista johtuvia merkittäviä ongelmia, rajattiin tämän työn ulkopuolelle. Tutkimuksen ulkopuolelle jätettiin kokonaan Töysässä sijaitseva toinen koelohko, sillä kuvaus ei onnistunut teknisten ongelmien vuoksi.

Työn liitteinä olivat liitteet (1–16): ylimääräiset kuvauskerrat, muutama esimerkkikartta epäonnistuneesta kuvauksesta, korjuuaikanäytteen täydentävät tulokset, salaojakartat, lehtialaindeksimittauksen täydentävät tulokset.

4.9 Tulosten esitys


Mitattujen ja kuvattujen muuttujien välistä riippuvuutta tutkittiin korrelaatio ja regressioanalyysillä havaintokohdista. Tulokset on esitetty pääosin lohkoakohtaisesti tarkasteltuna. P-arvoja tässä tutkimuksessa ei laskettu yksittäisten mittausten vähäisyyden vuoksi. Biomassaa (kuiva) on verrattu kalibroituihin kasvillisuusindeksikarttoihin ja Red edge -kameran kaistoihin kaikkien lohkojen havaintoja yhdessä.


5 TULOKSET

Tutkimustulokset on esitetty lohkoittain esitettynä havaintokohdittain sekä osaa tuloksista yhdistettynä. Tuloksissa on vertailtu kasvuston pituutta, lehtialaindeksiä ja lehtivihreän määrää biomassaan (kuiva-aine) lohkoittain. Lisäksi kasvillisuusindeksejä: NDVI, EVI ja NDRE sekä Red edge -kameran mittaamia kaistoja: punainen, sininen, vihreä, red-edge ja lähi-infrapuna on verrattu biomassaan lohkoittain ja kaikkia yhdessä. Lopuksi on käsitelty DLS anturista johtuvia kuvausvirheitä.

5.1 Koirasuon B-osa ennen ensimmäistä niittoa

Koirasuon B-osan eli voimalinjan takana olevan koelohkon osan (Liite 1) osan ensimmäinen virallinen kuvaus tehtiin (6.6.2017) viikko ennen ensimmäistä säilörehusadon korjuuta, jolloin nurmen sulavan orgaanisen aineen osuus kuiva aineessa eli D-arvo oli 765 g/kg ka (Liite 4). Nurmen kasvuaste BBCH oli 35 mittaushetkellä. Kuva 10 karttasarjassa esitetään lohkolta otetuista kuvista yhdistämällä lasketut ortomosaiikit kaistoittain yhdistettynä havaintotunnuksiin.





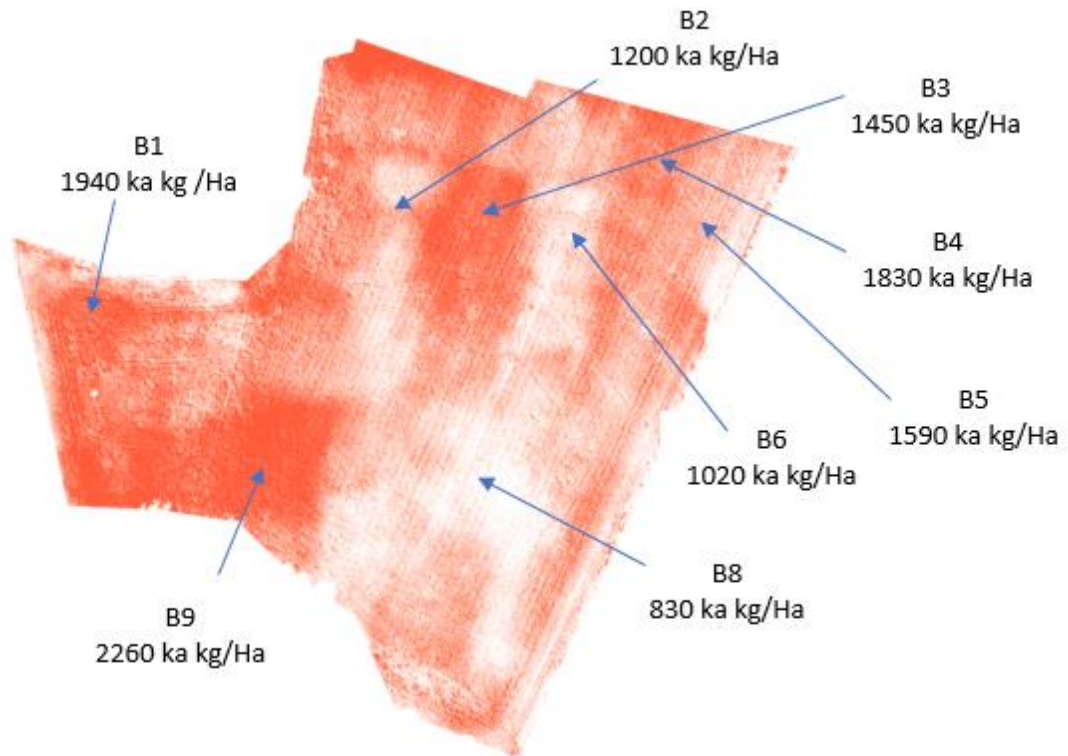
Kuva 10. Koirasuon B-osan ensimmäisen kuvauskerran ortomosaiikit kaistoittain. Karttasarjassa multispektrikameran kaistojen: sinisen, vihreän, punaisen, lähi-infrapunan ja red-edgen kartat sekä kasvillisuusindekseistä NDVI, EVI ja NDRE. Karttasarjassa olevat havaintokohdat on merkitty symbolilla B ja koodeilla 0-13. B0=kuvien yhdistämisestä johtuva karttavirhe, B1=runsas juolavehnäkasvusto, B2=kasvusto harvaa ja nurminatamättäitä, B3=timotei/nurminatakasvusto, B4 ja B5=juolavehnä-, nurminata-, timoteikasvusto, B6=koko-ojan kohta, B7=väkilannoite jäänyt levittämättä, B8=lyhyt nurminatavaltainen kasvusto, B9=runsas juolavehnäkasvusto, B10=väkilannoite jäänyt levittämättä, B11=kallio maanpinnassa, B12=voikukkia ja B13=kasvusto harvaa ja mättäitä. Liitteessä Liite 5 on esitetty tarkemmin symbolien takana olevat kasvusto/yleishavainnot.

Kuvatun alueen kokonaispinta-ala oli 3,45 ha rajauksen jälkeen (Kuva 10). Kartoista on rajattu pois pellon ulkopuolella olevat metsäalueet sekä puiden varjostamat alueet pellon laidoilta. Pohjoissuuntanuoli sekä mittakaava on esitetty vihreän aallonpituusalueen kartassa. Lentosuuntana oli Etelä–Pohjoinen. Kuvien yhdistämisestä johtuva virhe näkyy parhaiten sinisen aallonpituusalueen kartassa (Kuva 10, Blue, B0 kohdassa). Kuva 10 spatiaalinen resoluutio on 3,3 cm/pikseli.

Koirasuon B-osan ilmakuvista havaittiin tutkimusvuoden keväällä tehdyn rikkakasvien torjunnassa käsittelemätön kohta. Alue on merkitty Kuva 10 havaintotunnuksella B12. Lohkolla esiintyneet rikkakasvit voitiin tunnistaa vain lohkolle tehdyssä tarkastuksessa – ei ilmakuvasta. Samasta kuvasta on havaintotunnuksen B13 (liite 5) kohdalla havainto, ’kasvusto mätästää’. Ilmakuvista mättäät erottuvat taustasta (Kuva 10, havainto B13).


Lohko kuvattiin uudelleen kolme vuorokautta ensimmäisen kuvauskerran jälkeen (nurmen kasvuaste BBCH 37, jolloin D-arvo oli 750 g/kg ka) ja ortomosaiikkisarja on esitetty Liite 6. Liitteen vihreässä ortomosaiikissa on havaittavissa juolavehnapesäkkeitä, jotka on merkitty tunnuksella (O1) kuvaan. Keskiviikon 7.6. ja torstain 8.6. välisenä aikana kasvusto kasvoi pituutta 3 cm. Havainto on mitattu korjuuaikanäytteiden määrityskohdasta.

Kuva 11 on esitetty lohkon biomassahavainnot lohkon eri osissa yhdistettynä havaintotunnukseen. Punaisempi väri kuvassa kuvastaa suurempaa biomassan määrää ja valkoisempi väri pienempää biomassan määrää.




Kuva 11. Lohkon biomassakartta (kuiva-aine, ka). Suuntanuolilla havainnollistettu mistä kohtaa lohkoa korjuuaikanäytteet on otettu.

Kuva 12 on esitetty pituushavainnot biomassan funktiona havaintokohdista. Pituushavaintojen keskiarvo oli 41 cm ja näytteiden keskiarvon keskivirhe 3,2 cm. Regressioanalyysin selitysaste oli 95 %. Biomassahavaintojen keskiarvo oli 1520 kg ja näytteiden keskiarvojen keskivirhe 173 kg. Korjuuaikanäytteiden näytekohtaiset tulokset on esitetty Liite 4.




Kuva 12. Nurmikasvuston pituus Koirasuon kentällä esitettynä biomassan funktiona ja yhdistettynä havaintokohdan tunnuksiin kasvuasteessa BBCH 35, jolloin D-arvo oli 765 g/kg ka. X-akselilla kasvuston biomassa ja Y-akselilla kasvuston pituus. Havaintokohdat esitetty kartalla (Kuva 11).

Kuva 13 on esitetty lehtivihreän pitoisuus biomassan funktiona. Regressionanalyysin selitysaste oli 74 %. Lehtivihreämittausten keskiarvo oli 279 $\mu\text{mol}/\text{m}^2$ ja havaintojen keskiarvon keskivirhe 9,1 $\mu\text{mol}/\text{m}^2$.




Kuva 13. Lehtivihreän määrä Koirasuon loholla esitettynä biomassan funktiona nurmen kasvuasteessa BBCH 35, jolloin D-arvo oli 765 g/kg ka. X-akselilla on esitetty biomassa ja Y-akselilla lehtivihreäpitoisuus. Havaintokohdat esitetty kartalla (Kuva 11).

Lehtialaindeksi on esitetty biomassan funktiona Kuva 14. Liite 7 on esitetty lehtialaindeksimittauksen havaintopaikkakohtaiset tulokset. Regressionanalyysin selitysaste oli 82 % ja lehtialaindeksihavaintojen keskiarvo 2,54. Havaintojen keskiarvon keskivirhe oli 0,44.



Kuva 14. Lehtialaindeksi biomassan funktiona Koirasuon lohkollla. X-akselilla biomassa ja Y-akselilla lehtialaindeksi. Mittaus kasvuasteessa BBCH 35, jolloin D-arvo oli 765 g/kg ka. Havaintokohdat esitetty kartalla (Kuva 11).

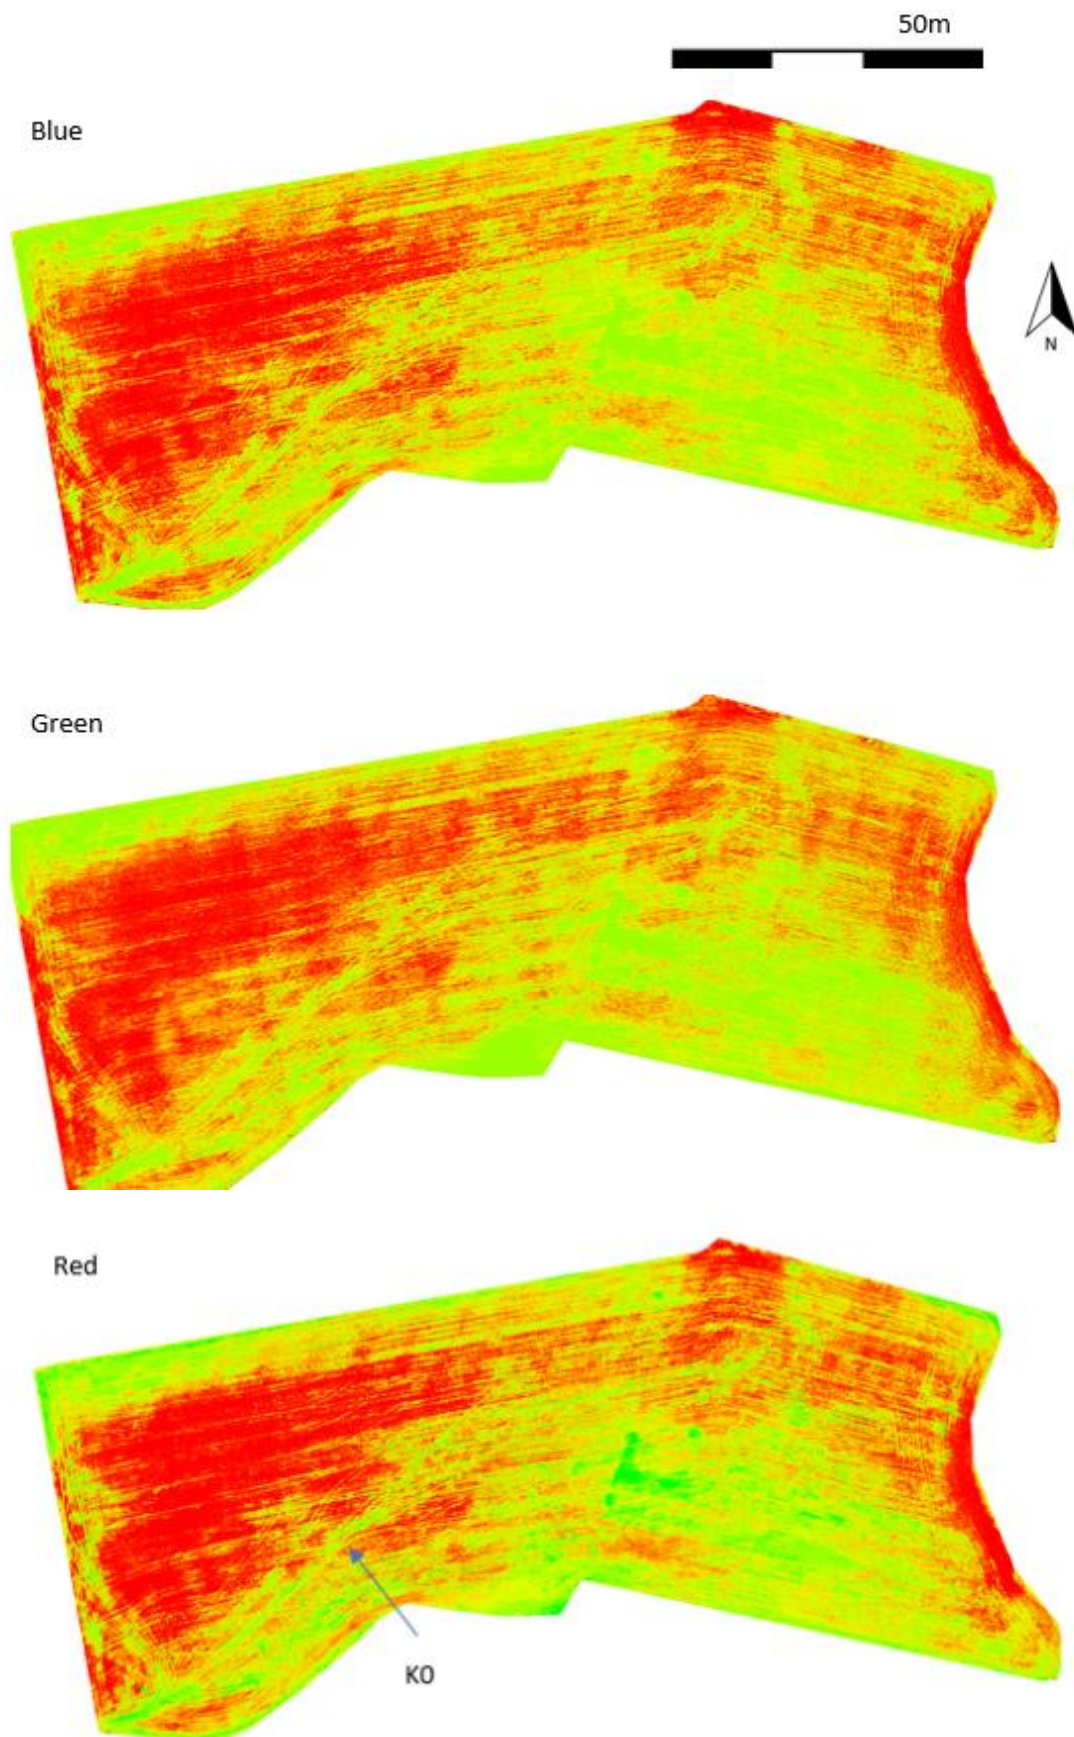
Keskimääräinen pikselin heijastusarvo määritettiin havaintokohdista 50x50 pikselin alueelta jokaiselta multispektrikameran kaistalta sekä kaistoilta lasketuista kasvillisuusindekseistä EVI, NDVI ja NDRE. Pellolla tämä alue vastasi 43,56 m² alaa. Heijastuksen voimakkuus Red edge kameran aallonpituusalueilla sekä kasvillisuusindeksien heijastuksen voimakkuudet on esitetty Kuva 15.




Kuva 15. Heijastuksen voimakkuus esitettynä biomassan funktiona kasvuasteessa BBCH 35, jolloin D-arvo oli 765 g/kg ka. Biomassa x-akselilla ja y-akselilla heijastuksen voimakkuus. Kuvassa valoista: punainen, sininen, vihreä, red-edge, lähi-infrapuna ja kasvillisuusindekseistä: NDVI, NDRE ja EVI. Punainen ja sininen kaista ovat kuvassa päällekkäin ja erottuvat huonosti.


5.2 Isokytö ennen ensimmäistä niittoa

Töysän Kitulanmäessä olevan koelohkon ensimmäinen kuvaus tehtiin 13 päivää ennen ensimmäistä niittoa nurmen kasvuasteessa BBCH 25, jolloin D-arvo oli 770 g/kg ka. Ortomosaiikeista rajattiin pois pellon ulkopuoliset alueet sekä puiden varjojen aiheuttamat virheet. Kuvatun alueen kokonaisala oli rajauksien jälkeen 6,4 hehtaaria. Kuva 16 karttasarjassa on esitetty lohkolta otetuista kuvista yhdistämällä lasketut ortomosaiikit kaistoittain yhdistettynä havaintotunnuksiin. Pohjoissuuntanuoli sekä mittakaava on esitetty sinisen kaistan ortomosaiikin vasemmassa yläreunassa. Kuva 16 spatiaalinen resoluutio oli 3,3 cm/pikseli.







Red Edge



NDVI






Kuva 16. Kitulanmäen koelohkon (Isokytö) tulokset ortomosaiikkeina (karttasarja). Ortomosaiikkisarjassa on multispektrikameran kaistojen: sinisen, vihreän, punaisen, lähi-infrapun ja red-eden kartat sekä kasvillisuusindekseistä NDVI, EVI ja NDRE. Ortomosaiikkisarjassa olevat havaintokohdat on merkitty symbolilla K ja koodeilla 1-13. K1=ajouria, K2=timotei/nurminatakasvusto, K3 ja K4=väkilannoite jäänyt levittämättä, K5=märkä kohta ja ei kasvillisuutta, K6=hevonhierakkaa kasvustossa, K7=runsaasti hevonhierakkaa, K8=Runsaasti hevonhierakkaa ja rönsyleinikkiä, K9 ja K10=notkopaikka, ei kasvillisuutta, K11=timotei/nurminatakasvusto, K12=harva kohta, K13=kaista, jonne ei ole väkilannoitetta levitetty. Liite 8 on esitetty symbolien takana olevat kasvusto/yleishavainnot tarkemmin.

Kitulanmäen koelohkon karttasarjassa (Kuva 16) ei esiinny kuvien yhdistämisestä johtuvaa virhettä ja kuvaus onnistui ongelmitta. Ortomosaiikeissa esiintyvä virhe johtui automaattikirkkaussäätöisen kameras valoanturin (DLS anturin) asennon muutoksesta auringon suuntaan. Aurinkoon päin lennettäessä kameras kirkkaus muuttui verrattuna lentämiseen auringosta poispäin. Ongelma ilmeni ortomosaiikeissa dronen lentoreittiä noudattelevina vääristyminä eli osa alueista heijasti voimakkaammin ja kuin normaalisti. Ongelmaa esiintyi kahdella seuraavalla kuvauskerralla 13.6.2017 (Liite 9) ja 18.6.2017 (Liite 10).

Ilmakuvista ei voitu tunnistaa lohkon rikkakasveja eikä alueita, joissa oli paljas maanpinta erottaa kasvustosta ilman lohkolle tehtyä tarkastusta. Lohkolle esiintyi runsaasti rikkakasveja: voikukkaa, rönsyleinikkiä ja hevонhierakkaa (Liite 8, havainnot K6, K2 ja K8).


Kuva 17 on yhdistetty lohkon lähi-infrapunakarttaan biomassahavainnot. Havainnot on esitetty 10 kg tarkkuudella. Mitä enemmän punaista väriä kartassa sitä enemmän lohkolle on biomassaa. Nuolilla on havainnollistettu korjuuaikänäytteiden ottokohdat.



Kuva 17. Isokytö -lohkon biomassakartta (kuiva-aine, ka).


Kuva 18 on esitetty kasvuston pituushavainnot biomassan funktiona. Regressioanalyysin selityssasteeksi oli 80 %. Kasvuston keskipituus oli mittaushetkellä 32 cm ja

pituushavaintojen keskiarvon keskivirhe 2,9 cm. Keskimääräinen biomassa lohkolla oli 842 kg ka/ha ja näytteiden keskiarvon keskivirhe 162 kg. Liite 11 on esitetty havaintokohtaiset tulokset tarkemmin.




Kuva 18. Kasvuston pituus Isokyrön kentällä esitettynä biomassan funktiona ja yhdistettynä havaintotunnuksiin kasvuasteessa BBCH 25, jolloin D-arvo oli 761 g/kg ka. X-akselilla kasvuston biomassa ja Y-akselilla kasvuston pituus. Havaintokohdat esitetty kartalla (Kuva 17).

Kuva 19 on esitetty lehtivihreän määrä biomassan funktiona. Regressioanalyysin selityssasteeksi oli 8 %. Lehtivihreänäytteiden keskiarvo 310 $\mu\text{mol}/\text{m}^2$ ja havaintojen keskiarvon keskivirhe 21 $\mu\text{mol}/\text{m}^2$. 0-tason typpikaistojen lehtivihreänäytteiden keskiarvo oli 291 $\mu\text{mol}/\text{m}^2$ ja kaistan ulkopuolisten havaintojen keskiarvo 321 $\mu\text{mol}/\text{m}^2$.




Kuva 19. Lehtivihreän määrä Isokyrön koelohkolla esitettynä biomassan funktiona nurmen kasvuasteessa BBCH 25, jolloin D-arvo oli 761 g kg/ka. X-akselilla on esitetty biomassa ja Y-akselilla lehtivihreäpitoisuus. Havaintokohdat esitetty kartalla (Kuva 17).

Kuva 20 on esitetty lehtialaindeksi biomassan funktiona. Regressioanalyysin selitysaste oli 61 % Lehtialaindeksihavaintojen keskiarvo oli 2,10 ja havaintojen keskiarvon keskivirhe 0,48. Liite 12 on esitetty lehtialaindeksimittausten havaintokohtaiset tulokset tarkemmin.



Kuva 20. Lehtialaindeksi Isokyrön koelohkolla esitettynä biomassan funktiona. Lehtialaindeksi biomassan funktiona. X-akselilla biomass ja Y-akselilla lehtialaindeksi. Mittaus nurmen kasvuvaiheessa BBCH 25, jolloin D-arvo oli 761 g/kg ka. Havaintokohdat esitetty kartalla (Kuva 17).

Heijastuskartasta laskettiin jokaisen biomassanäytekohdan 50x50 matriisin alalta eli 44,10 m² alalta keskimääräinen pikselien arvo. Arvo laskettiin jokaiselta Multispektrikameran kaistalta sekä kasvillisuusindeksien NDVI, NDRE ja EVI osalta. Tulokset on esitetty Kuva 21.

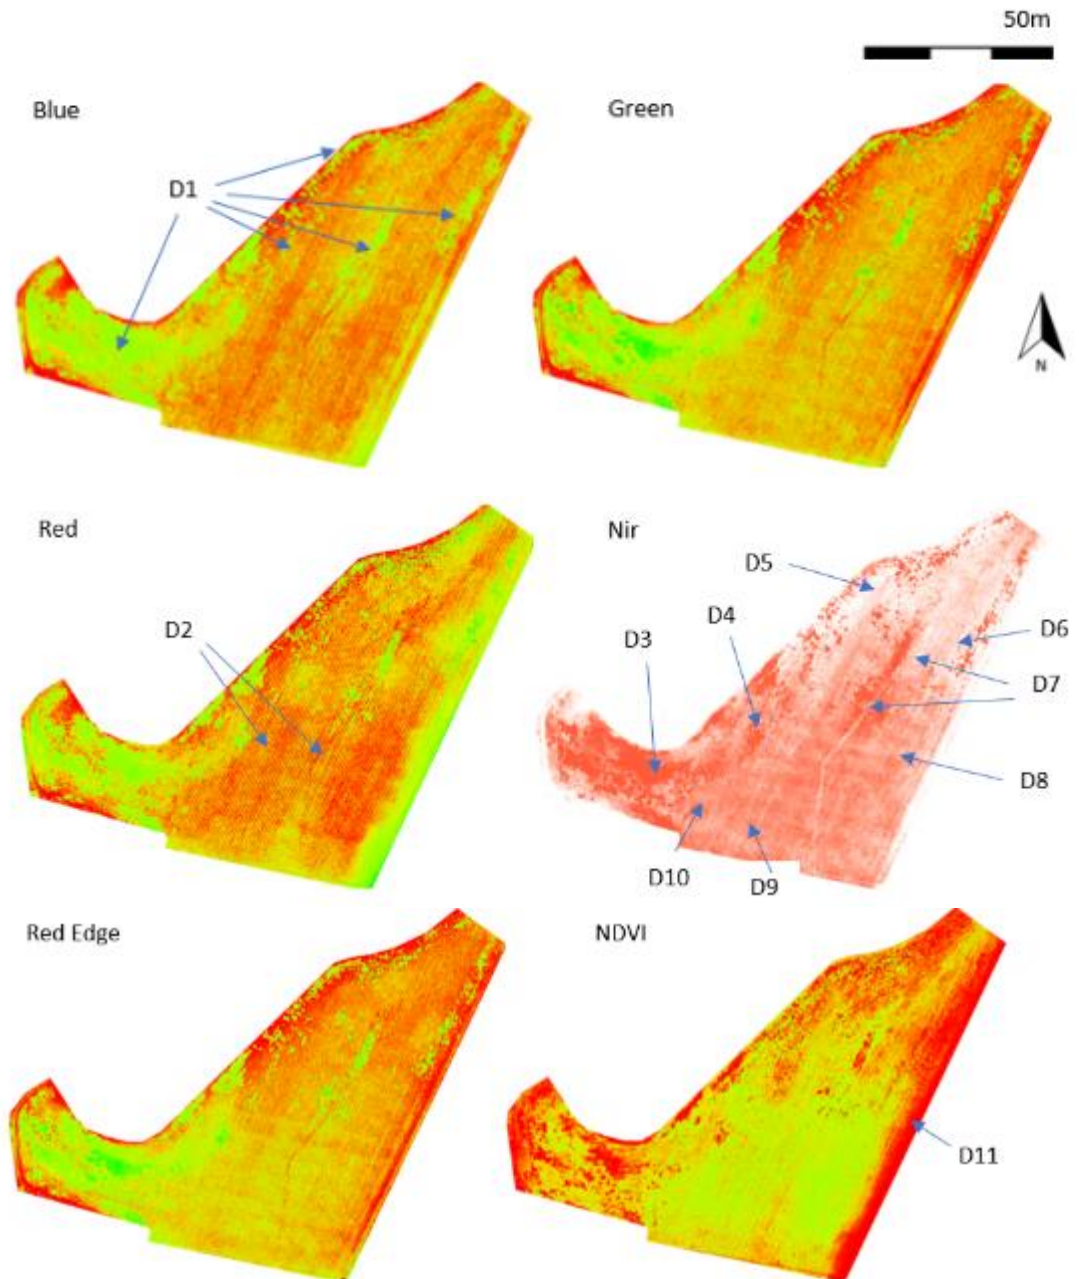



Kuva 21. Heijastuksen voimakkuus esitettynä biomassan funktiona. Biomassa x-akselilla ja y-akselilla heijastuksen voimakkuus. Kuvassa valoista: punainen, sininen, vihreä, red-edge, lähi-infrapuna ja kasvillisuusindekseistä: NDVI, NDRE ja EVI. Kuva kasvuasteessa BBCH 25, jolloin D-arvo oli 770 g/kg ka.

5.3 Koirasuon A-osa ennen toista niittoa

Koirasuon koelohkon voimalinjan etummainen osa (Liite 1) eli A-osa kuvattiin onnistuneesti ensimmäisen kerran toiselle sadolle nurmen kasvuasteessa BBCH 35, jolloin D-arvo oli 708 g/kg ka (Liite 13). Kuvaus ja näytteiden otto tapahtui 6 päivää

ennen niittoa. Kuvatun alueen kokonaisala oli rajauksen jälkeen 7,01 hehtaaria ja spatiaalinen resoluutio 3,3 cm/pikseli. Kuva 22 karttasarjassa esitetään lohkolta otetuista kuvista yhdistämällä lasketut ortomosaiikit yhdistettynä havaintotunnuksiin.






Kuva 22. Koirasuon A-osan kuvat ortomosaiikkeina (karttasarja). Ortomosaiikkissa multispektrikameran kaistojen: sinisen, vihreän, punaisen, lähi-infrapun ja red-edgen kartat sekä kasvillisuusindekseistä NDVI, EVI ja NDRE. Ortomosaiikissa olevat havaintokohdat on merkitty symbolilla D ja koodeilla 1-11. D1=juolavehnäpesäkkeitä, D2=DLS anturista johtuva kuvausvirhe, D3=laossa oleva juolavehnäkasvusto, D4=juolavehnä/nurminatakasvusto, D5=kasvustossa aukkoja, D6=kasvustossa sadon korjuussa syntyneitä vauriota, D7=koko-ojan kohta, D8 ja D9=nurminata/timotei/juolavehnäkasvusto, D10=voikukkaa runsaasti, D11=talviaikaisen hiihtoladun kohta, natavaltainen kasvusto. Liite 14 on esitetty symbolien takana olevat kasvusto/yleishavainnot tarkemmin.


Koirasuon A-osan (Kuva 22) kasvustokartassa esiintyy jonkin verran virhettä, joka johtuu kameran valosensorin suuntauksesta aurinkoon nähden. Häiriö on merkitty tunnuksella D2 kuvaan ja se on havaittavissa parhaiten punaisen ja lähi-infrapunakaistan ortomosaiikkeista. Häiriö ilmenee kartassa voimakkaampana punaisen värinä kuin normaalisti. Liite 15 on esitetty lähi-infrakamerakuvista laskettu kartta samalta lohkon ensimmäisestä sadosta. Kyseisessä kartassa on havaittavissa ilmiön ääriesimerkki.

Kuva 23 on lohkon lähi-infrapunakartta, johon on merkitty biomassa 10 kg tarkkuudella. Punaisempi väri kuvassa kuvastaa suurempaa biomassan määrää ja valkoisempi väri pienempää biomassan määrää. Keskeltä lohkoa menevän koko-ojan paikka näkyy kuvassa lohkon läpi kulkevana haaleana viiruna. Tarkemmin se on esitetty Kuva 22 havaintotunnuksella D7.




Kuva 23. Koirasuo A-osan biomassakartta (kuiva-aine, ka).

Kuva 24 on esitetty korjuuaikanäytteistä määritetty nurmen biomassa sekä havaintopaikasta mitattu nurmen pituus. Korjuuaikanäytteen täydentävät tulokset on esitetty Liite 13. Kasvuston pituus biomassan funktiona on esitetty Kuva 24 ja regressioanalyysin selitysaste oli 67 %. Kasvuston keskipituus oli 36 cm ja keskiarvon keskivirhe 2,3 cm. Biomassan keskiarvo oli 1290 kg ja keskiarvon keskivirhe 211 kg.




Kuva 24. Kasvuston pituus esitettynä biomassan funktiona ja yhdistettynä havaintotunnuksiin kasvuasteessa BBCH 35, jolloin D-arvo oli 708 g/kg ka. X-akselilla kasvuston biomassa ja Y-akselilla kasvuston pituus. Havaintokohdat esitetty kartalla (Kuva 23).

Lehtivihreän määrä biomassan funktiona on esitetty Kuva 25. Regressioanalyysin selityssaste oli 11 %. Lehtivihreän määrän keskiarvo oli 280 $\mu\text{mol}/\text{m}^2$ ja keskiarvon keskivirhe 14 $\mu\text{mol}/\text{m}^2$.




Kuva 25. Lehtivihreän määrä esitettynä biomassan funktiona nurmen kasvuasteessa BBCH 35, jolloin D-arvo oli 708 g kg/ka. X-akselilla on esitetty biomassa ja Y-akselilla lehtivihreäpitoisuus. Havaintokohdat esitetty kartalla (Kuva 23).

Lehtialaindeksi on esitetty biomassan funktiona Kuva 26. Regressioanalyysin selitysaste oli 93 %. Lehtialaindeksin keskiarvo oli 4,1 ja keskiarvon keskivirhe 0,4. Näytteenottohetkellä sää oli puolipilvinen. Lehtialaindeksin mittauksen tarkentavat tulokset on esitetty Liite 16.



Kuva 26. Lehtialaindeksi biomassan funktiona. X-akselilla biomassa ja Y-askelilla lehtialaindeksi. Mittaus kasvuasteessa BBCH 35, jolloin D-arvo oli 708 g/kg ka. Havaintokohdat esitetty kartalla (Kuva 23).


Heijastusarvo laskettiin 50x50 pikselin alalta jokaisesta korjuuaikanäytteen ottokohdasta jokaiselta multispektrikameran kaistalta sekä kaistoilta lasketuista kasvillisuusindekseistä EVI, NDVI ja NDRE. Oheisessa kartassa (pellolla) tämä alue vastasi 43,82 m² alaa. Kuva 27 on esitetty pikselien heijastusarvot biomassan funktiona.




Kuva 27. Heijastuksen voimakkuus esitettynä biomassan funktiona. Biomassa x-akselilla ja y-akselilla heijastuksen voimakkuus. Kuvassa valoista: punainen, sininen, vihreä, red-edge, lähi-infrapuna ja kasvillisuusindekseistä: NDVI, NDRE ja EVI. Kuva kasvuasteessa BBCH 35, jolloin D-arvo oli 708 g/kg ka. Punainen ja sininen kaista ovat kuvassa päällekkäin ja erottuvat huonosti.

5.4 DLS anturista johtuvat kuvausvirheet

Kuvausten aikana Koirasuon B-osan kuviin syntyi jonkin verran häiriötä esim. Kuva 10 havainto B0. Häiriö johtui suurella todennäköisyydellä DLS anturista. Poispäin auringosta lennettäessä automaattisäätö sääti kirkkautta vaikka, sitä ei olisi tarvinnut ja samoin aurinkoon päin lennettäessä (Kuva 28 ja Kuva 29). Ongelmaa esiintyi myös Koirasuon kuvauksessa 9.6.2017 (Liite 6), Koirasuon A-osan kuvauksessa 8.6.2017 (Liite 15) ja Töysän kuvauksissa Liite 9 ja Liite 10. Ongelma aiheutti karttoihin lentoreittien mukaista aallonharjakuviota ja osa alueista oli kirkkaampia tai haaleampia kuin todellisuudessa (Kuva 29).




Kuva 28. Auringon vaikutus DSL-anturiin.



Kuva 29. Koirasuon A-osa ennen ensimmäistä niittoa nurmen kasvuasteessa BBCH 40, jolloin D-arvo oli 765 g/kg ka. Kuvassa esimerkki DLS anturin aiheuttamasta häiriöstä karttoihin.

5.5 Lohkojen yhdistetyt biomassa- ja heijastusarvot

Kaikista koelohkoista yhdistettiin biomassahavainnot havaintokohdasta kunkin kaistan keskimääräiseen heijastuspikselin arvoon. Tulokset on esitetty Kuva 30.



Kuva 30. Heijastuksen voimakkuus esitettynä biomassan funktiona kaikki havaintolohkojen havaintokohdat yhdistettynä. Biomassa x-akselilla ja y-akselilla heijastuksen voimakkuus. Kuvassa valoista: punainen, sininen, vihreä, red-edge, lähi-infrapuna ja kasvillisuusindekseistä: NDVI, NDRE ja EVI.

6 TULOSTEN TARKASTELU

Tässä osiossa käydään läpi tulokset lohkoakohtaisesti sekä osaa lohkoakohtaisista tuloksista yhdessä. Lisäksi tuloksia verrataan kirjallisuudessa esitettyihin aiempien tutkimustulosten tuloksiin. Kuvausvirheiden käsittely ei tässä työssä ollut tavoitteena, mutta tutkielman teon aikana nousu esiin yksi merkittävä virhelähde liittyen DLS-anturiin, jonka käsittely tämän työn tulosten kannalta oli merkittävää.

6.1 Kuvausvirheet

DLS-anturi aiheutti indeksikarttoihin virhettä, joka ilmeni kuvatussa kohteessa normaalista poikkeavina heijastusarvoina, jotka riippuivat lentosuunnasta aurinkoon nähden. Kuitenkaan DLS-anturin virhemahdollisuutta tai ohjelman kykenemättömyyttä kuvien käsittelyyn ei voida näiden tulosten perusteella täysin sulkea pois. Sen osoittamiseksi vaadittaisiin toinen Red Edge-kamera ja DLS-anturille vakain, joka pitäisi sen koko ajan kohtisuorassa ylöspäin (Micasense 2015). Eli vastaava tutkimus eri Red Edge-kameralla. Ongelma esiintyi koko kesän ajan aurinkoisina ja puolipilvisinä päivinä. Sen sijaan pilvisinä päivinä ongelmaa ei esiintynyt, mikä viittaa DLS-anturista ja kameran vakaajasta aiheutuviin ongelmiin. Ongelman laajuutta kuvaa se, että yli puolet kesän 2017 aikana kerätyistä kuvamateriaalista oli käyttökelvotonta. Kirjallisuudesta ei löytynyt tuloksissa havaitulle ilmiölle. Ainoastaan maininta, että pohjoisissa kuvausoloissa auringon kulma on huomioitava ja keskipäivä on suositeltava kuvausajankohta (Thenkabail 2016a, Pix4D 2017a ja Pix4D 2017b).

Kirjallisuudessa todettiin puiden ja pilvien varjojen sekä kuvaussään vaihtelun aiheuttavan vääristymiä karttoihin (Zabala 2017, Elliott 2016 ja Thenkabailin 2016a). Tässä tutkimuksessa kerätyssä aineistossa valaistusolojen vaihtelusta aiheutuneet virheet ortomosaiikeissa olivat sen verran pieniä, ettei niistä kokonaisuuden kannalta ollut merkitystä. Varjoista sen sijaan oli haittaa, sillä varjoisen alueen valaistusolot ovat erilaiset kuin varjoa ympäröivällä alueella, mikä vaikuttaa myös kasvustossa heijastuvaan säteilyyn (Knipling 1970, Berni ym. 2009, Campbell ja Randolph 2011). Puiden aiheuttamat varjoalueet jouduttiin tästä syystä rajaamaan aineistosta pois väärrien tulkintojen estämiseksi. Rajatut alueet olivat muutamia metrejä pellon reunasta, joten kokonaisuuden kannalta niillä ei ollut merkitystä peltomittakaavan tutkimuksessa.

6.2 Biomassan määrän arviointi

Kirjallisuuden perusteella muun muassa ortomosaiikkia lähi-infrapuna-alueen säteilystä ja NDVI -indeksiä voidaan käyttää apuna biomassan määrän arviontiin (Tucker 1979, Viljanen ym. 2018). Tuckerin (1979) tutkimuksessa lähi-infrapunasäteilyn ja nurmen biomassan selitysasteeksi saatiin 86 %. Vastaavasti Viljasen ym. (2018) tutkimuksessa nurmen ja NDVI-indeksin selitysasteeksi saatiin 82 %.

Tämän tutkimuksen tulosten perusteella voidaan todeta, että lähi-infrapunakarttaa voidaan käyttää kasvillisuudesta täystiheillä lohkoilla biomassan karkeaan arviontiin. NDVI -indeksin käyttäminen biomassan arviontiin nurmikasvustoissa on haasteellista, sillä täystiheässä kasvustossa NDVI-indeksi kasvaa hitaammin kuin biomassan määrä lisääntyy (Mutanga ja Skidmore 2002). Ongelmaa esiintyy etenkin paljon biomassaa (LAI -arvo yli 4) tuottavilla kasvustoilla kuten nurmella (Mutanga ja Skidmore 2002).

Arvioidessa radiometriselle tarkkuudelle optimoituja ortomosaiikkeja lohkoilta eri ajankohtana kasvukauden aikana, lähi-infrapuna-alueen ortomosaiikkii ei anna kovin luotettavaa kuvaa lohkon biomassasta, jos kasvusto ei ole ummessa. Tutkimustuloksia vääristi Isokyrön paljas maanpinta ja lohkoilla oleva runsas rikkakasvien määrä. Etenkin hevonhierakan ja voikukan suurilla lehdillä oli kiistaton vaikutus heijastustuloksiin, jotka vaikuttivat ortomosaiikista laskettun biomassan arvion tarkkuuteen. Havainto tukee kirjallisuutta, jossa todettiin mm. maanpinnan ja rikkakasvien vääristävän todellista heijastusta (Knippling 1970, Campbell ja Randolph 2011).

DLS-anturin toimimattomuudesta johtuen vertailun kannalta parhaaseen ajankohtaan kuvatut ortomosaiikit jouduttiin kuitenkin hylkäämään. Tarkempien johtopäätösten tekemistä varten tarvitaan lisää kuvauksia sekä biomassanäytteitä eri olosuhteissa peltomittakaavassa.

6.3 Pikselien arvot ja biomassa

Yhdistettyjen havaintojen perusteella pikselien heijastusarvo esitettynä biomassan funktiona selitti biomassan vaihtelua vähän kaikilla näkyvän valon kaistoilla. Vastaavasti selitysaste oli suurempi biomassan ja kasvillisuusindeksien sekä lähi-infrapunakaistan lukemien välillä. Koirasuon B-osan lohkoilla vahvimmat selitysasteet olivat EVI-indeksillä ja lähi-infrapunalla nurmen biomassan kuiva-aineen välillä. Isokyrön

koelohkon kohdalla lähi-infrapunalla selityssaste oli kohtalainen. Koirasuon A-osan kohdalla suurimmat selityssasteet olivat EVI-indeksillä ja lähi-infrapunalla. Lohkojen yhdistetyssä vertailussa parhaiten nurmen biomassaa kuiva-aineena selitti lähi-infrapuna $R^2 = 55$. Kirjallisuudessa esitetyt tutkimustulokset tukevat myös osittain tätä havaintoa ja suurta vaihtelua esiintyy aiempien tutkimusten tuloksissa (Tucker 1979, Mutangan & Skidmore 2002, Cho ym 2007, Viljanen ym. 2018).

Yksiselitteistä syytä heijastusarvon suuriin vaihteluihin mittauksen välillä ei havaittu tässä tutkimuksessa. Eroja saattoivat selittää kasvusto- ja yleishavaintojen perusteella muun muassa nurmikasvilajikevaihtelut, ajourat, kasvuston tiheys, lannoitustaso, aiempi maankäyttö, paljas pellon pinta ja ongelmat pellon kuivatuksessa. Vastaavien havaintojen on kirjallisuudessa osoitettu vaikuttavan kasvuston heijastusomainsuuksiin (Knipling 1970, Berni ym. 2009, Campbell ja Randolph 2011).

6.4 Referenssinäytehavainnot ja kasvillisuusindeksit

Lohkoilla olevat rikkakasvit vaikuttivat tuloksiin voimakkaasti ja antoivat erityisesti heijastustuloksiin paremman kuvan mitä todellisuus oli. Lohkoista eniten ongelmaa esiintyi Isokyrön lohkokolla, jossa oli laajoja alueita, jossa kasvoi runsaasti rikkakasveja. Paljas maanpinta lohkokolla heijasti enemmän kuin kasvillisuus näkyvän valon alueella ja lähi-infrapuna alueella vähemmän kuin kasvillisuus (Knipling 1970, Berni ym. 2009, Campbell ja Randolph 2011). Erityisesti edellä mainittu ilmiö aiheutti Isokyrön lohkokolla virhettä indeksikarttoihin ja lehtialaindeksimittaustuloksiin. Toisaalta rikkakasveja ja kasvillisuudesta tyhjiä alueita esiintyy normaalisti lohkokolla, joten kokonaiskuva kuvastaa todellisuutta.

Koirasuon B-osan kuvasarjasta ja Isokyrön kuvasarjasta erottuivat myös kohdat, jonne ei ollut levitetty väkilannoitetta. Typpilannoitus vaikuttaa kasvien heijastusarvoon, joten alueet erottuivat indeksikartoista (Schlemmer ym. 2010, Grunzehauser ym. 2013). Tosin Isokyrön typpilannoituksen nollakohta erottuu indeksikartoista, mutta lohkon lehtivihreämittauksessa kaistaa ei erota kirjallisuudesta poiketen muusta kasvustosta (Schlemmer ym. 2013). Se miksi kaista ei erotu lehtivihreämittauksessa johtuu todennäköisesti suuresta vaihtelusta laitteen antamissa tuloksissa tässä tutkimuksessa mitatuilla nurmikasveilla sekä lohkon lannoitushistoriasta. Väkilannoittamattomalla alueella kasvusto oli myös lyhyempää kuin väkilannoitteen saaneilla alueilla.

Indeksikarttojen heijastusarvon vaihtelua eri alueilla ei voida kuitenkaan tulkita täysin väkilannoitteen vähäisyydestä johtuvaksi, sillä muun muassa Koirasuon talvenaikainen hiihtolatu ja Isokyrön lietteen levitysurat saattoivat osaltaan vaikuttaa kasvuston pituuteen sekä lajikevalikoimaan. Kasvusto saattoi kärsiä näillä aluilla abioottisesta tai bioottisesta stressistä (Jakson 1986, Tikka 2010).

Indeksikarttojen pohjalta yksittäisten rikkakasvien tunnistaminen lohkolta on haasteellista, sillä saman pikselin alueella saattaa olla useita eri kasvilajikkeita. Kasvien heijastus riippuu monesta eri tekijästä, joten rikkakasvien tunnistaminen kasvillisuudesta seasta on erittäin haasteellista, jos rikkakasvin heijastus ei poikkea merkittävästi taustan eli normaalin kasvillisuuden heijastuksesta (Knippling 1970, Berni ym. 2009, Campbell ja Randolph 2011). Koelohkoilta ei tunnistettu indekseistä rikkakasveja, mutta yhdistämällä kasvustohavainnot indeksikarttoihin joitain rikkakasvialueita pystyttiin tunnistamaan visuaalisesti.

Maaperän kosteusmuutokset sekä maan rakennemuutokset vaikuttavat kasvillisuuteen (Thenkabailin 2016a/b). Salaojien kohdat sekä aiempi maankäyttö voi tämän perusteella vaikuttaa kasvillisuusindeksikarttoihin. Koirasuon B-osan ortomosaiikeista on havaittavissa kokooja-ojan kohta. Isokyrön ortomosaiikeista on tunnistettavissa imuojien kohdat. Tältä tutkimuksessa kuvatulta lohkolta on hukassa salaojakartta, joten ilmakuvia voidaan käyttää uuden kartan laadinnan apuvälineenä. Visuaalisesti arvioituna parhaiten imujen kohdat erottuvat lähi-infrapunakartasta. Koirasuon A-osan ilmakuvista on erotettavissa kokoojaojan kohta sekä osa siitä lähtevistä imuojista. Kasvustokäynneillä salaojien paikkoja ei pystynyt erottamaan kasvuston seasta, mutta ilmakuvauksen avulla kohdat pystyttiin määrittämään kartalle.

Kasvuston lajike-erojen tunnistaminen on mahdollista, jos käytetään riittävän tarkkaa kameraa, jotta eri kasvien heijastus voidaan erottaa toisistaan (Campbell ja Randolph 2011). Vastaavaan lopputulokseen voi päästä myös lentokorkeutta laskemalla, mutta tällöin yhden akun varauksella pystytään kuvaamaan pienempi ala kuin korkealla lentäen. Kuitenkin nurmikasvustossa timotei ja nurminata kasvavat sekaisin ja saman pikselin alueella saattaa olla sekä nata- että timoteikasvi. Omat havainnot tukevat kirjallisuuden havaintoa ja indeksikartoista on vaikea erottaa nurmilajikkeita toisistaan. Toisaalta keväällä nurminata on hitaampi lähtemään kasvuun kuin timotei/juolavehnä ja kasvuston

biomassaa vertailemalla eri alueilla varhaisessa kasvun vaiheessa, voidaan päätellä alueet, jossa kasvaa natavaltaisia lajikkeita (Peltonen ym. 2010). Havaintoa tukee koirasuon B-osan biomassakartta.

Indeksien kalibrointia varten lohkoilta tehtiin lehti-alaindeksi, lehtivihreä ja pituusmittauksia. Näitä havaintoja verrattiin biomassaan korrelaation avulla. Jos indeksien ja biomassan määrän riippuvuussuhteiden on riittävän vahva, niin kaukokartoituksen avulla voidaan myös näitä arvoja määrittää nurmiseoskasvustosta. Thenkabailin (2016a) totesi näiden referenssiaineistomittausten olevan työläitä kerätä laajassa mittakaavassa.

Kasvuston pituushavainnolla sekä lehtialaindeksihavainnolla havaittiin olevan voimakas korrelaatio biomassaan, kuten aiemmissa tutkimuksissa on havaittu (Campbell ja Randolph 2011). Lehti-alaindeksin osalta suuri lehtien määrä pudottaa korrelaatiota suurilla biomassan määrillä ja rajaa lehti-alaindeksin käytettävyyden varhaiseen kasvun vaiheeseen (Mutanga ja Skidmore 2002). Kasvuston lakoontumisen ei havaittu vaikuttavan lehtialaindeksin mittaustuloksiin tässä tutkimuksessa. Kasvuston tiheyden muutokset vastaavasti vaikuttavat kasvuston pituuteen. Kasvusto kasvaa pidemmäksi alueilla, jossa kasvuston tiheys on alhaisempi kuin täystiheillä alueilla (Peltonen ym. 2010). Vastaavaa havaintoa tuki Isokyrön loholla lohkoilla tehdyt mittaukset.

Kirjallisuuden perusteella lehtivihreällä on yhteys typpitasoon homogeenisissa kasvustossa eli samaa lajiketta kasvavassa kasvustoissa ja lehtivihreäkarttaa on käytetty lannoituskarttana (Mroz ja Sobieraj 2004, Novona 2013, Thenkabailin 2015b). Tässä tutkimuksessa ei suoraan tutkittu typpilannoituksen vaikutusta heijastustuloksiin. Lehtivihreää verrattiin biomassahavaintoihin lohkoilla ja tuloksissa havaittiin suurta vaihtelua eri mittausten välillä. Tulosten perusteella lehtivihreän perusteella biomassan määrittäminen nurmiseoskasvustosta on haasteellista. Tämä kertoo myös siitä, että lehtivihreämittausten tuloksia on haasteellista käyttää seoskasvustoissa lannoituskarttana.

Mittauksissa havaittiin suurta vaihtelua jopa samassa kasvin lehdessä. Havainto viittaisi lehtivihreäpitoisuuden mittaamisen vaikeuteen. Vaihtelu oli suurta myös eri nurmilajikkeiden välillä. Mittaus tehtiin sattumanvaraisesti eri nurmikasvilajikkeista, mikä ei ollut vertailun kannalta paras ratkaisu. Toisaalta nurmikasvustot ovat yleensä seoskasvustoja, voi edellisen perusteella olettaa kasvuston eri kasvilajien määrän lisäävän lehtivihreän mittaamisen vaikeutta. Multispektrikamera ei erottele kasvustoja toisistaan

ja täten yksittäisessä pikselissä saattoi olla useampia lajeja. Sen vuoksi eri lajien mittaaminen havaintopisteistä oli perusteltua.

6.5 Muuta havaittua

Elliott (2016) ja Halliday (2017) mainitsivat UAV rakennusvaiheessa hyvän tasapainotuksen helpottavan lentämistä sekä vähentävän sähkön kulutusta. Tämän tutkimuksen havaintolaitteiden rakennusvaiheessa tehtiin vastaava havainto RedEdge kameran vakaimen kanssa, jossa tasapainotuksen havaittiin vähentävän harjattomien sähkömoottorien virrankulutusta huomattavasti ja pidentävän täten lentoaikaa. Toinen havainto liittyi siihen, että hyvä tasapainostus mahdollisti pienempien harjattomien moottorien käytön vakaimessa ja myös vähentynyt paino pidentäisi lentoaikaa.

7 JOHTOPÄÄTÖKSET

Loppupäätelmänä voidaan todeta, että lähi-infrapunakarttaa ja NDVI -indeksikarttaa voidaan käyttää karkeana indikaattorina lohkon biomassan määrittämiseen nurmiseoskasvustoissa. Lehtien suuri määrä kasvustossa aiheuttaa suurilla biomassamäärillä epätarkkuutta kasvillisuusindeksipohjaiseen biomassan määrittämiseen. Ilmakuvien avulla voidaan tunnistaa heikosti kasvavien alueiden koko ja sijainti. Kasvukauden alussa ilmakuvat sopivat hyvin kasvustojen havainnointiin, jolloin toisaalta korjaavat toimenpiteet on mahdollista tehdä. Kasvustoton vaihtelun lohkon osissa voidaan olettaa johtuvan myös maaperästä, mutta sen tarkempaa johtopäätöstä pelkän karttapohjaisen tarkastelun perusteella ei voida tehdä.

Drone on erinomainen apu kasvustokäynnin tueksi. Toisaalta ilman kasvustokäyntiä, kuvien hyödyntäminen on haastavaa, koska kuvasta ei saada tietoa vaihtelun syistä. Kuvissa eri asiat aiheuttavat samanlaisen heijastuksen ja se mistä ero johtuu, on mahdotonta selvittää ilman lähempää tarkastelua. Kuvien hyödyntäminen täsmäviljelyssä on dronekuvien mahdollinen käyttökohde. Kuvien käsittely ja analysointi on tällä hetkellä paljon aikaa vievä työvaihe. Erityisesti biomassan tai kasvuston ominaisuuksien ennustamisessa multispektrikameran avulla on vielä paljon epävarmuutta. Tämän tutkimuksen tulosten perusteella jatkotutkimukset ovat tarpeellisia nurmikasvustoilla erityisesti seoskasvustoilla.

8 KIITOKSET

Kiitän Ossi Keisalaa Töysän kuvauslohkoista sekä yhteistyöstä kuvauksissa ja aineiston keruussa. Kiitän myös Hannu Torvista hyvistä neuvoista ja vinkeistä ja Hannu Mikkolalle tutkielman oikoluvusta. Mikko Hakojärveä ja Laura Alakukkua kiitän työn ohjaamisesta.

LÄHTEET

- Antila, A., Niskanen, M., Palva, R., Puumala, L. & Vallinhovi, S. 2014. NurmiArtturi-hanke. Hävikit kuriin ja säilörehun laadunvaihtelu hallintaan. Vaasa: Fram Oy.
https://www.proagria.fi/sites/default/files/attachment/nurmiartturi-lehti_pienempi_resoluutio_2.pdf. Päivitetty 24.6.2014, viitattu 22.1.2017.
- Apogee Devices Inc. 2017. Apogee Chlorophyll Concentration Meter Model MC-100. USA, Utah. <https://www.apogeeinstruments.co.uk/mc-100-chlorophyll-concentration-meter/>. Päivitetty 20.11.2017, viitattu 20.11.2017.
- Baichtal, J. 2015. Building Your Own Drones. A Beginner`s Guide To Drones, UAVs, and ROVs. USA, Indiana: Que Publishing.
- Berni, A.J., Zarco-Tejada, P.J., Suarez, L. & Fereres, E. 2009. Thermal and Narrowband Multispectral Remote Sensing for Vegetation Monitoring Froman Unmanned Aerial Vehicle. IEEE Geoscience and Remote Sensing Society 47: 722-738.
- Blackburn. G.A. 2006. Hyperspectral remote sensing of plant pigments. Journal of Experimental Botany 58: 855-867.
- Boegh, E., Soegaard, H., Broge, N., Hasager, C., Jensen, K., Schelde, K. & Thomsen, A. 2002. Airborne Multi-spectral Data for Quantifying Leaf Area Index. Nitrogen Concetration and Photosynthetic Efficiency in Agriculture. Remote Sensing of Environmment 81: 179-193.
- Campbell, J., Randolph, W. 2011. Introduction to Remote Sensing, Fifth Edition. USA, New York: The Guilford Press.
- Chang, S., Collins, W. 1983. Confismation of the airbourne biogeophysical mineral exploration technique using laboratory methods. Economic Geology 78: 723.
- Chavan, T., Nandedkar, A. 2018. AgroAVNET for crops and weed classification: A spep forward in automatic farming. Computer and Electronics in Agriculture 150: 361-372.

Cho, M., Skidmore, A., Corsi, F., Wiren, S., Sobhan, I. 2007. Estimation of green grass/herb biomass from airborne hyperspectral imagery using spectral indices and partial least squares regression. *International Journal of Applied Earth Observation and Geoinformation* 9: 414-424.

Davidson, S., Santos, M., Sloan, V., Watts, J., Phoenix, G., Oechel, W., Zona, D. 2016. Mapping Arctic Tundra Vegetation Communities Using Field Spectroscopy and Multispectral Satellite Data in North Alaska, USA. *Remote Sensing of Environment* 12: 978.

Decagon Devices Inc. 2017. Degagon AccuPAR LP-80 PAR/LAI sensor. http://manuals.decagon.com/Manuals/10242_Accupar%20LP80_Web.pdf. USA: Pullman. Päivitetty 10.7.2017, viitattu 20.11.2017.

Elliott, A. 2016. Build Your Own Drone Manual. Owners` Workshop Manual. The practical guide to safely building, operation and maintaining an Unmanned Aerial Vehicle (UAV). USA, California: Haynes Publishing.

EASA (European Aviation Safety Agency) 2017. Euroopan lentoliikenneturvallisuusvirasto. Luonnos uudesta EU-direktiivistä liittyen dronejen säätelyyn. Päivitetty 23.7.2017, viitattu 23.7.2017.

Eurooppa-neuvosto 2018. Euroopan Unionin neuvosto. Droonit: EU:n lentoturvallisuuden uudistus. <https://www.consilium.europa.eu/fi/policies/drones/> Päivitetty 4.10.2018, viitattu 14.11.2018.

Euroopan parlamentin ja neuvoston asetus (EY) N:o 785/2004. Lentoliikenteen harjoittajia ja ilma-alusten käyttäjiä koskevista vakuutusvaatimuksista. <http://eur-lex.europa.eu/legal-content/FI/TXT/?qid=1432649203336&uri=CELEX%3A02004R0785-20100408>. Päivitetty 23.7.2017, viitattu 23.7.2017.

FAOSTAT (Food and Agriculture Organization Corporate Statistical Database). 2016. <http://www.fao.org/faostat/en/#data>. Päivitetty 20.1.2017, viitattu 22.1.2017.

Franke, J., Menz, G., Oerke, E.C., Rascher, U. 2005. Comparison of multi-and hyperspectral imaging data of leaf rust infected wheat plants. *Remote Sensing for Agriculture, Ecosystems, and Hydrology* 5976d.

Gitelson, A.A., Merzlyak, M.N. 1994. Quantitative estimation of chlorophyll-a using reflectance spectra: experiments with autumn chestnut and maple leaves. *J Photochem Photobiol* 22: 247-252.

Grunzhauser, B., Shanahan, J. 2013. Use of Remote Sensing Imagery for Improving Crop Management Decisions.

<https://www.pioneer.com/home/site/us/agronomy/library/remote-sensing-imagery/>. Viitattu 30.1.2019, päivitetty 30.1.2019.

Ruini, F. 2011. Distributed Control for Collective Behaviour in Micro-Unmanned Aerial Vehicles.

https://www.researchgate.net/profile/Fabio_Ruini/publication/255968165_Distributed_Control_for_Collective_Behaviour_in_Micro-unmanned_Aerial_Vehicles/links/00b495211ecb299321000000/Distributed-Control-for-Collective-Behaviour-in-Micro-unmanned-Aerial-Vehicles.pdf?origin=publication_detail. Päivitetty 20.1.2019, viitattu 20.1.2019.

Gitelson, A., Gritz, Y., Merzlyak, M.N. 2003. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal Plant Physiology* 160: 271-282.

Gitelson, A., Keydan, G. & Merzlyak, M. 2006. Three band model for noninvasive estimation chlorophyll, catetenoids, and anthocyanin contents in higher plan leaves. University of Nebraska, Lincoln DigitalCommons@University of Nebraska – Lincoln. *Papers in Natural resources* 258.

Halliday, B. 2017. Drones: The complete collection Three books in one. Drones The Professional Drone Pilot's Manual, Drones Mastering Flight Techniques, Drones Fly Your Drone Anywhere Without Getting Busted. USA, Scotts Valley: CreateSpace Publishing.

- Hatfield, P.L., Printer, P.J. 1993. Remote sensing for crop protection. Contribution from the USDA-Agricultural Research Service 12: 403-413.
- Hatfield, J., Gitelson, A., Schepers, J., Walthall, C. 2008. Application of spectral remote sensing for agronomic decisions. *Agronomy Journal* 100: 131-117.
- Huete, A., Justice, C., Liu, H. 1994. Development of Vegetation and Soil Indices for MODIS-EOS. *Remote Sensing of Environment* 49: 224-234.
- Huete, A., Liu, H.Q., Batchily, K., YanLeeuwen, W.A. 1997. Comparison of vegetation indices global set of TM images for EOS-MODIS. *Remote Sensing of Environment* 59: 440–451.
- Huete, A., Didan, K., Miura, T., Rodriguez, E.P. & Ferreira L.G. 2002. Overview of the Radiometric and Biophysical Performance of the MODIS Vegetation Indices. *Remote Sensing of Environment* 83:195-213.
- Holopainen, M., Tokola, T., Vastaranta, M., Heikkilä, J., Huitu, H., Laamanen, R & Alho, P. 2015. Geoinformatiikka luonnonvarojen hallinnassa. Helsingin yliopiston metsätieteiden laitoksen julkaisusarja 7: 1-52.
- Hunt, R., Hively, W., Fujikawa, S., Linden, D., Daughtry, McCarty, G. 2010. Acquisition of NIR-Green-Blue Digital Photographs from Unmanned Aircraft for Crop Monitoring. *Remote Sensing* 2: 290-305.
- Ilmailulaki 864/2014 9, 57, 70 §. <https://www.finlex.fi/fi/laki/ajantasa/2014/20140864>. Päivitetty 19.1.2019, viitattu 19.1.2019.
- Issa R.A., Flood, I., O'Brien, W.J. 2003. 4D CAD and Visualization in Construction: Developments and Applications. Netherlands, Rotterdam: Balkema Publishers.
- Jackson, R. 1986. Remote Sensing of Biotic And Abiotic Plant Stress. US Water Conservation Laboratory, Agricultural Research Service, US Department of Agriculture, Phoenix Arizona 24: 265-287.
- Jensen, J.R. 2005. Introductory digital image processing: A Remote Sensing perspective 3rd ed. USA: Prentice Hall, Upper Saddle River. p. 505-512.

Knipling, E.B. 1970. Physical and Physiological Basis for the Reflectance of Visible and Near-Infrared Radiation from Vegetation. *Remote Sensing of Environment* 1: 155-159.

Luke (Luonnonvarakeskus) 2011. Alueittainen maidontuotanto 2011. http://stat.luke.fi/alueittainen-maidontuotanto-20102011_fi. Päivitetty 27.5.2011, viitattu 31.10.2015.

Luke (Luonnonvarakeskus) 2014. Maatalous- ja puutarhayritysten rakenne 2014. http://stat.luke.fi/alueittainen-maidontuotanto-20102011_fi. Päivitetty 27.5.2011, viitattu 31.10.2015.

Luke (Luonnonvarakeskus) 2016. Maataloustilastot. <http://stat.luke.fi/maatalous> Päivitetty 7.2.2016, viitattu 7.2.2016.

Luke (Luonnonvarakeskus) 2019. Tilastotietokanta. <https://stat.luke.fi/>. Päivitetty 5.4.2019, viitattu 5.4.2019.

Mashall Devices Inc. 2017. Mashall Mettler Toleda PM 4600 User Manual. https://www.marshallscientific.com/v/vspfiles/specs/MTAMPM_specs.pdf. Päivitetty 20.11.2017, viitattu 20.11.2017.

Matsushita, B., Yang, W., Onda, Y., Qiu, G. 2007. Sensitivity of the Enhanced Vegetation Index (EVI) and Normalized Difference Vegetation Index (NDVI) to Topographic Effects: A Case Study in High-Density Cypress Forest. *US National Library of Medicine National Institutes of Health* 11: 2636-2651.

Micasense 2015. RedEdge User Manual. Micasense RedEdge TM 3 Multispectral Camera User Manual Rev 06 – Rev 06 October 2015. <https://support.micasense.com/hc/en-us/articles/215261448-RedEdge-User-Manual-PDF-Download->. Päivitetty 6.10.2015, viitattu 14.11.2017.

Mroz, M. & Sobieraj, A. 2004. Comparison of several vegetation indices calculated on the basis of a seasonal spot xs time series, and their suitability for land cover and agricultural crop identification. Department of Photogrammetry and Remote Sensing University of Warmia and Mazury in Olsztyn.

http://www.uwm.edu.pl/wnt/technicalsc/ts7_2004/4_7_2004.pdf. Päivitetty 12.7.2017, viitattu 3.12.2018.

MTK (Maataloustuottajien keskusjärjestö) 2014. Maatilojen kehitysnäkymät 2020.

https://www.mtk.fi/liitot/varsinaissuomi/fi_FI/tukikoulutuskalenteri/_files/93967700274277250/default/Maatilojen%20kehitysn%C3%A4kym%C3%A4t_MTK-Varsinais-Suomi.pdf. Päivitetty 6.9.2015, viitattu 22.1.2017.

Mutanga, O. & Skidmore, A.K. 2002. Narrow band vegetation indices overcome the saturation problem in biomass estimation. *International Journal of Remote Sensing* 25: 19.

Nilsson, H.E. 1995. Remote Sensing And Image Analysis In Plant Pathology.

Laboratory For Phytopathology, Department of Plant Pathology, Swedish University of Agriculture Sciences 15: 489-527.

Novotna, K., Rajnerova, P., Misa. P., Misa. M. & Klem, K. 2013. Normalized Red-Edge index- New Reflectance Index For Diagnostics of Nitrogen Status In Barley.

http://web2.mendelu.cz/af_291_mendelnet/mendelnet2013/articles/41_novotna_909.pdf Julkaistu 2013, viitattu 4.3.2018.

Peltonen, S., Puurunen, T. & Harmoinen. T. 2010. Nurmirehujen tuotanto ja käyttö.

ProAgria Keskusten Liiton julkaisuja nro 1094. Hämeenlinna: Kariston kirjapaino.

Paul, J., Printer, J.R., Jerry, L., Hatfield P.L, James, S., Schepers,. Edwaed, M., Barnes, M., Morran, S., Craig, S.T., Daughtry,. Upchurch, R.D. 2003. Remote Sensing For Crop Management. *Photogrammetric Engineering & Remote Sensing* 6: 647-664.

Pix4D 2017a. Pix4D Support. <https://support.pix4d.com/hc/en-us#gsc.tab=0>.

Switzerland, Lausanne. Julkaistu 2011-2017, viitattu 14.11.2017.

Pix4D. 2017b. Pix4Dmapper 3.3 User Manual.

<https://support.pix4d.com/hc/en-us/articles/204272989-Offline-Getting-Started-and-Manual-pdf-#gsc.tab=0>. Switzerland, Lausanne. Julkaistu 2011-2017, viitattu 14.11.2017.

Poutanen, M. 1999. GPS-paikanmääritys. Hämeenlinna: Tähtitieteellinen yhdistys URSA.

Pöllönen, I., Saari, H., Kaivosoja, J., Honkavaara, E., Pesonen, L. 2013. Hyperspectral imaging based biomass and nitrogen content estimations from light-weight UAV. Remote Sensing for Agriculture, Ecosystems, and Hydrology 8887: 15.

Richardson, A., Everitt, J., Gausman, H. 1983. Radiometric estimation of biomass and nitrogen content of Alicia grass. Remote Sensing of Environment 13: 179-184.

Rouse, J., Haas, R., Schell, J. & Deering, D. 1973. Monitoring Vegetation in the Great Plains with ERTS. Third ERTS Symposium. Remote Sensingcenter Texas A&M hiversity Colfegp Station Texas. NASA 309-317.
<https://ntrs.nasa.gov/search.jsp?R=19740022614>, Päivitetty 13.12.2018, viitattu 13.12.2018.

Rupert, B. 2017. Drones (The Ultimate Guide) How They Work, Learning to Fly, How to Fly, Building Your Own Drone, Buying a Drone, How to Shoot Photos. USA, Scotts Valley: CreateSpece Publishing.

Schlemmer, M., Gitelson, A., Schepers, J., Ferguson, R., Peng, Y., Shanaha, J., Rundguist D. 2013. Remote estimation of nitrogen and chlorophyll contents in maize at leaf and canopy levels. International Journal of Applied Earth Observation and Geoinformation 25: 47-54.

Saukkonen, L. 2008. Suomalainen sää, ilmastonmuutos ja ääri-ilmiöt. Helsinki: Minerva.

Seppänen, M., Mäkelä, P., Yli-Halla, M., Helenius, J., Kallela, M., Stoddard. F. & Teeri, T. 2008. Peltokasvien Tuotanto. Helsinki: Opetushallitus 206.

Suomen Gallup Elintarviketieto Oy TNS 2016. Maatilojen kehitysnäkymät 2022.
http://www.gallupnet.fi/maatila/Maatilojen_kehitysnakymat_2022.pdf. Päivitetty
 6.12.2016, viitattu 22.1.2016.

Thenkabail, P.S. 2016a. Land Resources Monitoring, Modeling, And Mapping With Remote Sensing. USA, Danvers: CRC Press.

Thenkabail, P.S. 2016b. Remotely Sensed Data Classification, and Accuracies. Remote Sensing Handbook Volume 1. USA, Danvers: CRC Press.

Tikka, J. 2010. Suojakasvina toimivan kultapiiskun (*Solidago virgaurea*) vaikutus naapurikasvien arbuskeli mykoritsa symbioosin sekä putkilo kasvien laji- ja ympäristömäärään tunturiniityllä. Pro Gradu -tutkielma. Jyväskylän yliopisto.
<https://jyx.jyu.fi/bitstream/handle/123456789/25389/1/URN%3ANBN%3Afi%3Aju-201010042900.pdf>. Viitattu 4.12.2018, päivitetty 4.12.2018.

Tike (Tilastokeskus) 2013. Maatalous- ja puutarhayritykset, työvoima ja monialaisuus. Suomi, Helsinki: Juvenes Print – Suomen Yliopistopaino Oy.

Trafi (Liikenteen turvallisuusvirasto) 2016. OPS M1-32 -määräys (määräys 90924/03.04.00.00/2016). Kauko-ohjatun ilma-aluksen ja lennokin lennättäminen.
https://www.trafi.fi/filebank/a/1482415412/c34a1bef37860a2559d61acf4fdebb3a/23514-OPS_M1-32_VALMIS_maarays_RPAS_fi.pdf. Julkaistu 23.12.2016, viitattu 31.7.2017.

Trafi (Liikenteen turvallisuusvirasto) 2017a. Usein kysyttyä/Ilmailu – Miehittämättömät ilma-alukset ja lennokit. https://www.trafi.fi/tietopalvelut/usein_kysyttya/ilmailu_-_miehittamattomat_ilma-alukset_ja_lennokit. Päivitetty 23.7.2017, viitattu 23.7.2017.

Trafi (Liikenteen turvallisuusvirasto) 2017b. RPAS lentotyötoiminta.
https://www.trafi.fi/ilmailu/miehittamaton_ilmailu/rpas_lentotyto. Päivitetty 23.7.2017, viitattu 23.7.2017.

Trafi (Liikenteen turvallisuusvirasto) 2017c. Uutiskirje 30.5.2017 Ajankohtaista ilmailussa. <http://trafi.mailpv.net/a/s/53568020->

71d1266f5299549a835f0d475509e078/1887429. Päivitetty 23.7.2017, viitattu 23.7.2017.

Tucker, C.J. 1979. Red and Photographic Infrared Linear Combinations for Monitoring Vegetation. *Remote Sensing of Environment* 8: 127-150.

User manual 3D Solo. 2017. https://3dr.com/support/articles/user_manual/. Päivitetty 15.6.2017, viitattu 15.6.2017.

TUG Team 2014. The UAV Guide <http://wiki.theuavguide.com/wiki/Multicopter>. Päivitetty 12.5.2014, viitattu 31.7.2017.

Viljanen, N., Honkavaara, E., Näsi, R., Hakala, T., Niemeläinen, O., Kaivosoja, J. 2018. A Novel Machine Learning Method for Estimating Biomass of Grass Swards Using a Photogrammetric Canopy Height Model, Images and Vegetation Indices Captured by a Drone. *Agriculture* 2018 8: Multidisciplinary Digital Publishing Institute. *Agriculture* 8: 70.

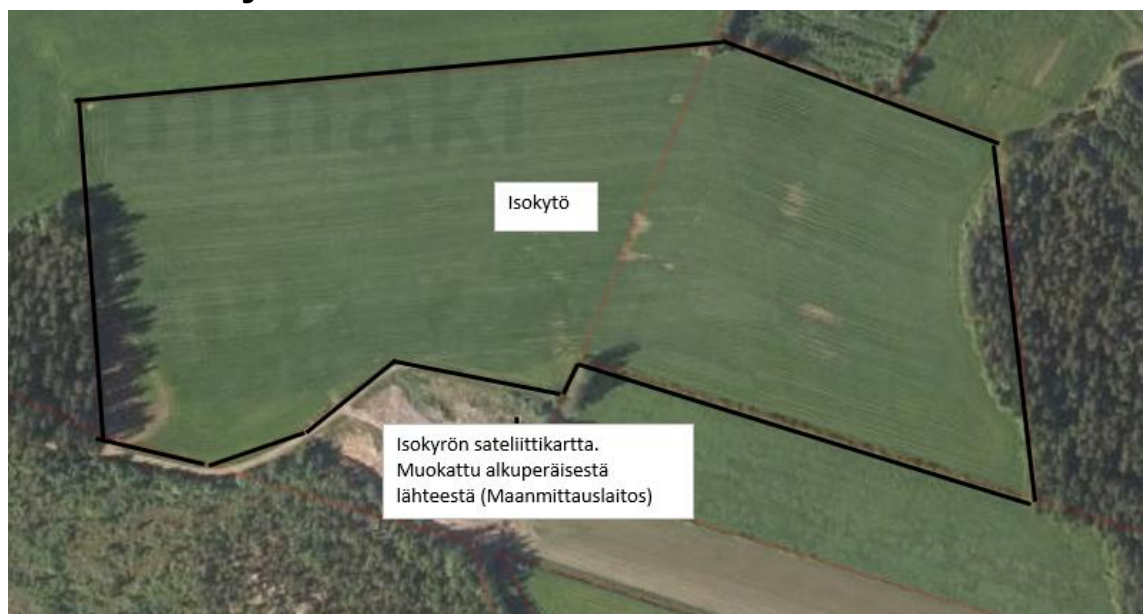
Zabala, S. 2017. Comparison of Multi-temporal and multispectral Sentinel-2 and Unmanned Aerial Vehicle imagery for crop type mapping. Department of Physical Geography and Ecosystem Science. Sweden: Lund University GEM thesis series NGEM 0120162.

Zhu, X., Helmer, E.H. 2018. An automatic method for screening clouds and cloud shadows in optical satellite image time series in cloudy regions. *Remote Sensing of Environment* 214: 135-153.

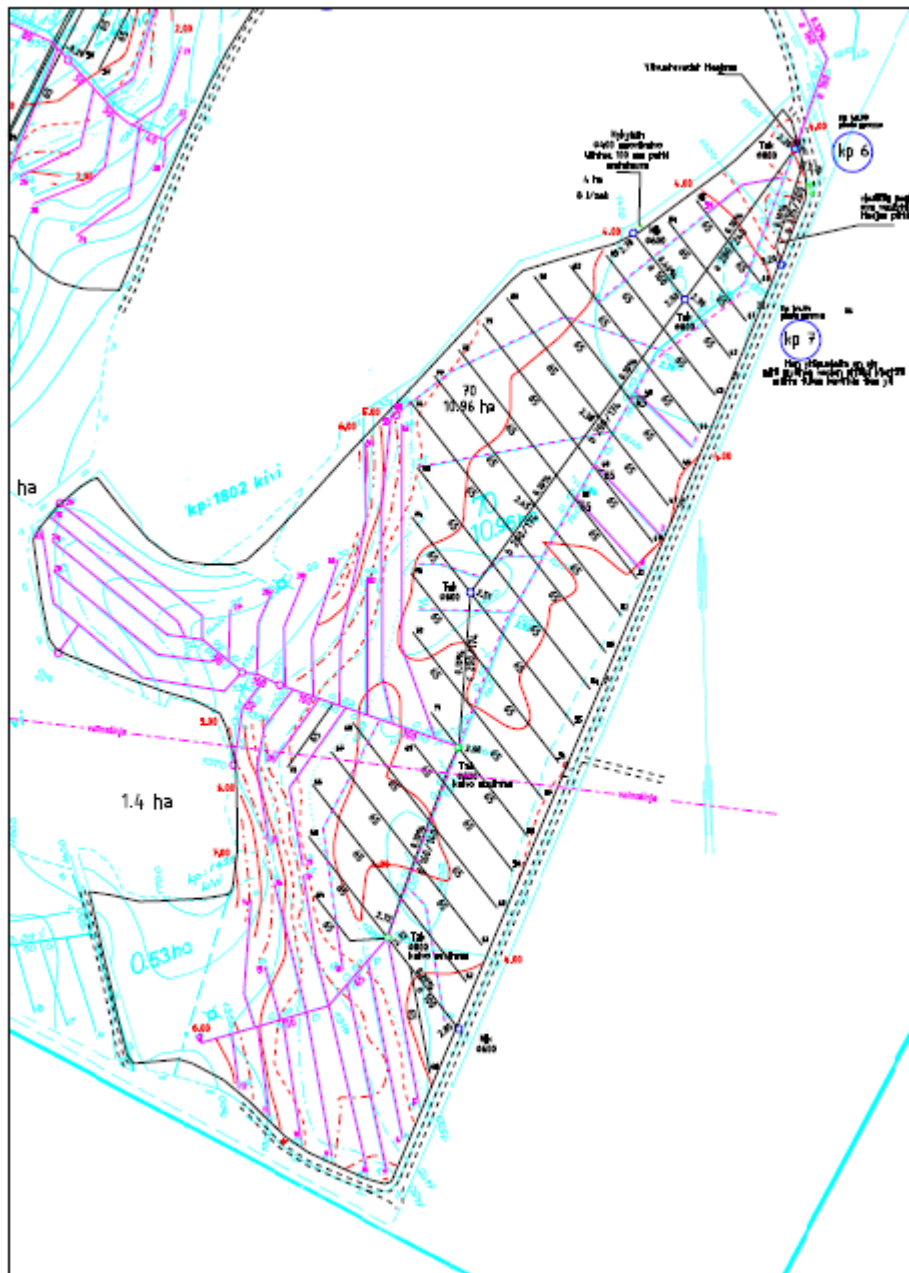
Liite 1. Koirasuon ilmakuva



Liite 2. Isokyrön ilmakuva



Liite 3. Koirasuon salaojakartta



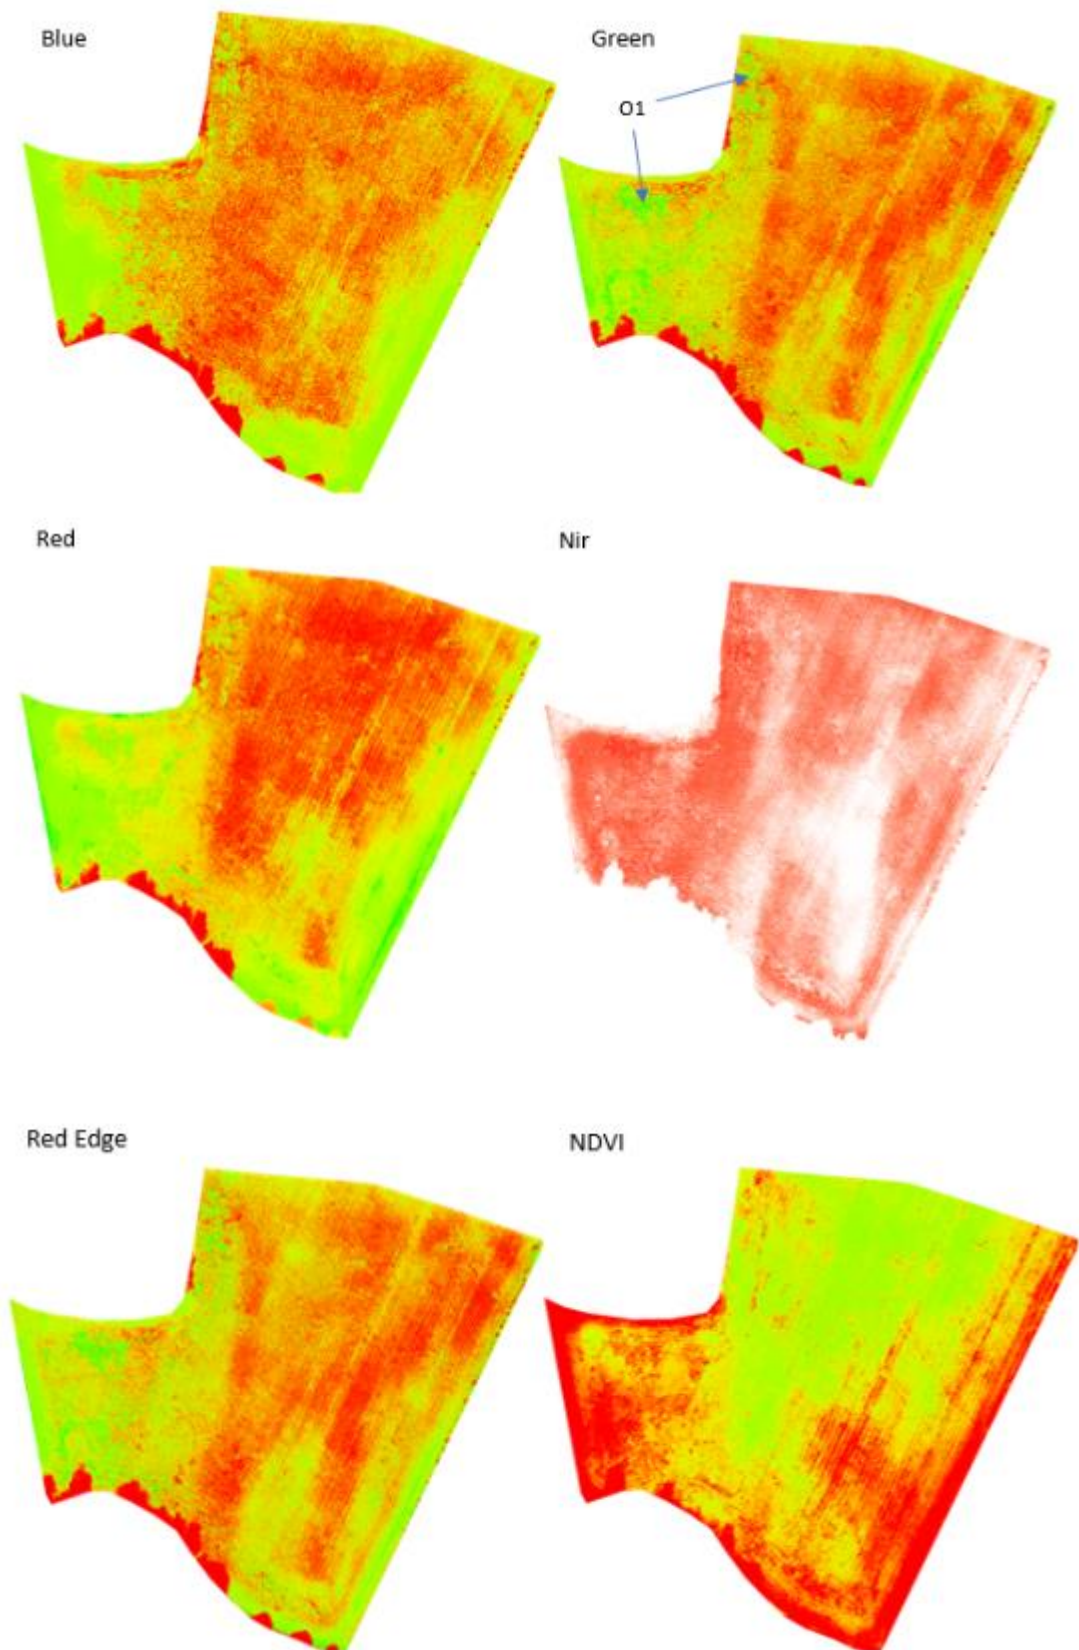
Liite 4. Koirasuon B-osan 1. sadon korjuuaikanäytteen havaintokohtaiset tulokset


Havaintotunnus	B8	B6	B2	B3	B5	B4	B1	B9	Keski-arvo	Keskiarvon keskivirhe
Näytteen paino kg	0,28	0,37	0,46	0,56	0,64	0,84	0,84	1,02	0,6	0,1
Kuiva-aine g/kg	297	275	260	258	249	218	231	222	251,3	9,6
Biomassa ka kg/ha	832	1018	1196	1445	1594	1831	1940	2264	1514,9	172,7
Pituus cm	28	33	32	40	41	45	52	53	40,5	3,2
Tiheys %	31	48	48	55	58	58	50	58	50,5	3,2
D-arvo g /kg ka	762	763	770	770	763	770	752	768	764,8	2,2
Rv (g/kg ka)	181	180	183	210	165	159	161	190	178,6	6,0
NDF (g/kg ka)	490	420	426	441	425	416	430	471	439,9	9,4
Sokeri (g/kg ka)	141	219	200	141	225	229	236	152	192,9	14,6
iNDF (g/kg ka)	36	18	31	20	31	30	31	30	28,4	2,2
Tuhka (g/kg ka)	70	70	68	80	63	64	58	66	67,4	2,3
ME (MJ/kg ka)	12	12,3	12,3	12,3	12,2	12,2	12,2	12,3	12,2	0,0
OIV (g/kg ka)	92	94	94	97	92	91	91	95	93,3	0,8
PVT (g/kg ka)	43	40	43	66	28	23	25	49	40	5,1

Liite 5. Koirasuon B-osan yleis- ja kasvustohavainnot

Tunnus	Havainto	Kartta
B1	Runsas juolavehnäkasvusto	Nir
B2	Mäen taittumisen kohta. Kasvusto on harvaa ja mätästää. Kasvustossa jonkin verran aukkoja ja kasvusto on lähinnä nurminataa ja ruokonataa	Nir
B3	Lähinnä timotei/nurminatakasvustoa	Nir
B4	Juolavehna-, nurminata- ja timoteikasvusto	Nir
B5	Juolavehna-, nurminata- ja timoteikasvusto	Nir
B6	Koko-ojan kohta. Kasvusto lähinnä nurminataa ja lyhyttä	Nir ja NDRE
B7	Väkilannoite jäänyt levittämättä 1. sadolle. Lyhyt ja harva nurminatakasvusto	Nir ja NDRE
B8	Erittäin harva ja lyhyt kasvusto. Lähinnä nurminataa	Nir
B9	Runsas juolavehnäkasvusto	Nir
B10	Väkilannoite jäänyt levittämättä 1. sadolle	Nir ja NDRE
B11	Kallio maanpinnassa. Ei kasvillisuutta	NDVI
B12	Kasvinsuojelumatton kohta. Voikukkaa	NDVI
B13	Kasvusto harvaa sekä mätästää	NDRE

**Liite 6. Koirasuon B-osan 1. sadon täydentävä kuvaus
9.6.2017**





Lentosuunta itä-länsi ja luode-kaakko

Liite 7. Koirasuon B-osan 1. sadon lehtialaindeksimittauksen tunnistekohtaiset tulokset


Tunniste	Aika	Keskimääräinen yläpuolinen PAR	Keskimääräinen alapuolinen PAR	Tau (T)	Lehtialaindeksi (LAI)	Lehtien levinneisyys (X)	Sädefraktio (Fb)
B1	8.6.2017 17:14:18	122,5	8,4	0,069	3,44	1,13	0,02
B2	8.6.2017 16:59:35	228,2	38,4	0,168	2,17	1,13	0,02
B3	8.6.2017 16:56:40	262,7	35,3	0,134	2,49	1,13	0,02
B4	8.6.2017 16:49:49	264,3	43,0	0,163	2,21	1,13	0,02
B6	8.6.2017 16:53:53	294,4	62,6	0,212	1,89	1,13	0,02
B7	8.6.2017 17:06:23	187,0	76,6	0,410	1,10	1,13	0,02
B8	8.6.2017 17:02:57	201,0	80,8	0,401	1,09	1,13	0,02
B9	8.6.2017 17:11:23	150,9	7,1	0,047	4,48	1,13	0,02
B10	8.6.2017 17:15:39	109,5	37,8	0,345	1,32	1,13	0,02

Liite 8. Isokyrön yleis- ja kasvustohavainnot


Tunnus	Havainto	Kartta
K0	Ajourat	Red
K1	Voikukkaa jonkin verran. Timotei/nurminatakasvusto	Nir
K2	Kasvusto harvaa. Typen puute näkyy. Voikukkaa jonkin verran	Nir
K3	Voikukkaa jonkin verran. Typen puute näkyy kasvustosta	Nir
K4	Typen puute erottuu heikommin. Paremmin kasvava kohta nolla typpitaso kaistalla	Nir
K5	Märkä kohta. Ei kasvillisuutta	Nir
K6	Kasvustossa runsaasti hevонhierakkaa. Jonkin verran voikukkaa	Nir
K7	Runsaasti hevонhierakkaa taimettunut	Nir
K8	Runsaasti hevонhierakkaa, rönsyleinikkiä ja muita rikkakasveja. Nurmea kasvuston seassa vähän. Märkä kohta	Nir
K9	Notko paikka ja märkä paikka. Ei kasvillisuutta	Nir
K10	Notko paikka ja märkä paikka. Ei kasvillisuutta	Nir
K11	Timotei/nurminatakasvusto	
K12	Harva ja paljon rikkakasvia kasvava kohta	EVI
K13	Kasvustokaista, jonne ei ole levitetty typpeä	NDRE

Liite 9. Töysä Keisala, Täydentävä kuvaus 13.6.2017. Kuvissa virhettä


Blue




Green




Red




Nir




Red Edge



NDVI




EVI



Itä

NDRE




Länsi


Lentosuunta länsi-itä

**Liite 10. Töysä Keisala, Täydentävä kuvaus 18.6.2017.
Kuvissa hieman virhettä.**


Blue



Green




Red




Nir




Red Edge



NDVI





Lentosuunta länsi-itä

Liite 11. Isokyrön 9.6.2017 korjuuaikanäytteen tunnuskohtaiset tulokset

Tunnus	K3	K8	K10	K6	K1	Keskiarvo	Keskiarvon keskivirhe
Näytteen paino kg	0,28	0,40	0,38	0,77	0,97	0,6	0,1
Kuiva-aine g/kg	176	154	172	144	138	156,8	7,5
Määrä ka kg/ha	493	616	654	1109	1339	842,0	162,2
Pituus cm	28	30	27	32	43	31,8	2,9
Tiheys %	67,5	80,0	37,5	85,0	75,0	69,0	8,4
D-arvo g /kg ka	763	765	759	761	762	762,0	1,0
Rv (g/kg ka)	296	199	299	250	253	259,4	18,3
NDF (g/kg ka)	473	473	469	435	456	461,2	7,3
Sokeri (g/kg ka)	61	131	59	106	101	91,6	13,9
iNDF (g/kg ka)	29	32	30	36	37	32,8	1,6
Tuhka (g/kg ka)	88	71	87	75	80	80,2	3,3

ME (MJ/kg ka)	12,2	12,2	12,2	12,2	12,1	12,2	0,0
OIV (g/kg ka)	106	96	106	101	101	102,0	1,9
PVT (g/kg ka)	142	58	146	102	105	110,6	16,0

Liite 12. Isokyrön 9.6.2017 lehtialaindeksin tunnistekohtaiset tulokset

Tunniste	Aika	Keskimääräinen yläpuolinen PAR	Keskimääräinen alapuolinen PAR	Tau (T)	Lehtiala indeksi (LAI)	Lehtien levinneisyys (X)	Sädefraktio (Fb)
K1	13.6.2017 14:16:53	1054,7	105,0	0,097	3,43	1,13	0,11
K2	13.6.2017 14:22:22	943,1	330,4	0,357	1,58	1,13	0,91
K3	13.6.2017 14:27:12	2048,1	803,8	0,392	1,72	1,13	0,91
K4	13.6.2017 14:31:47	2049,4	476,9	0,233	2,68	1,13	0,91
K6	13.6.2017 14:36:19	1823,9	349,1	0,193	3,06	1,13	0,91
K8	13.6.2017 14:50:30	1497,9	392,1	0,251	2,58	1,13	0,91
K11	13.6.2017 14:56:55	1867,9	822,1	0,441	1,45	1,13	0,91
K10	13.6.2017 14:43:31	504,6	247,9	0,492	0,89	1,13	0,00

Liite 13. Koirasuon A-osan 12.7.2017 korjuuaikanäytteen tunnuskohtaiset tulokset


Tunnus	D6	D5	D4	D9	D8	D3	Keskiarvo	Keskiarvon keskivirhe
Näytteen paino g	751	691	972	1076	1118	1717	1054	149,9
Kuiva- aine g/kg	177	213	174	180	187	154	181	7,9
Biomassa kg/ha	1330	1471	1692	1936	2090	2644	1861	194,5
Tiheys %	35	40	48	53	48	43	44	2,6
Pituus cm	34	29	38	32	37	45	36	2,3
D-arvo g /kg ka	721	720	712	690	714	693	708	5,5
Rv (g/kg ka)	245	239	255	186	218	260	234	11,3
NDF (g/kg ka)	493	498	521	529	483	533	510	8,5
Sokeri (g/kg ka)	81	88	67	101	97	68	84	5,9
iNDF (g/kg ka)	35	41	50	64	39	64	49	5,2
Tuhka (g/kg ka)	91	92	84	86	86	87	88	1,3

ME (MJ/kg ka)	11,5	11,4	11,4	11	11,5	11,1	11	0,1
OIV (g/kg ka)	96	95	97	87	93	95	94	1,5
PVT (g/kg ka)	104	100	114	58	81	122	97	9,6

Liite 14. Koirasuon A-osan kasvusto- ja yleishavainnot

Tunnus	Havainto	Kartta
D1	Juolavehnapesäkkeitä	Blue
D2	Kuvausvirhe, joka johtuu lentosuunnasta aurinkoon nähden ja DLS sensorin toiminnasta	Red
D3	Laossa oleva juolavehnaikasvusto	Nir ja NDRE
D4	Juolavehnaa, nurminataa sekä vähän voikukkaa. Rinteen pohjoisreuna	Nir
D5	Nurminata, juolavehna, vähän voikukkaa ja timoteitä. Heikosti kasvava kohta. Nurmen korjuusta syntyneitä aukkopaikkoja kasvustossa	Nir ja NDRE
D6	Nurminata, juolavehna ja vähän timoteitä. Kasvustossa nurmen korjuusta syntyneitä aukkopaikkoja	Nir ja NDRE
D7	Koko-ojan kohta. Osa koko-ojasta lähtevistä imuista näkyy.	Nir
D8	Nurminata, timotei ja juolavehnaikasvusto. Kasvustossa vähän myös voikukkaa	Nir
D9	Kasvustossa timoteitä, juolavehnaa, nurminataa ja vähän voikukkaa.	Nir
D10	Kasvustossa voikukkalaikku. Näkyy heikosti ilmakuvissa. Havaintokohdassa ei kasva muuta kuin voikukkaa	Nir
D11	Hiihtolatu. Näkyy kasvustossa lyhyempänä ja lähinnä nurminatakasvustona	NDVI

Liite 15. Koirasuon A-osan 1. sadon epäonnistunut kuvaus 8.6.2017



Lentosuunta itä-länsi ja pohjois-etelä

Liite 16. Koirasuon A-osan 13.7.2017 tunnistekohtaiset lehtialaindeksimittaukset

Tunniste	Aika	Keskimääräinen yläpuoleinen PAR	Keskimääräinen alapuoleinen PAR	Tau (T)	Lehtiala indeksi (LAI)	Lehtien levinneisyys (X)	Sädefraktio (Fb)
D3	14.7.2017 8:31:56	1435,1	8,7	0,006	5,71	1,13	0,91
D4	14.7.2017 8:35:08	1602,4	46,8	0,029	4,07	1,13	0,91
D5	14.7.2017 8:43:25	1369,7	67,0	0,050	3,50	1,13	0,91
D6	14.7.2017 8:46:42	1300,7	137,0	0,101	3,10	1,13	0,91
D8	14.7.2017 8:39:04	1405,1	34,3	0,025	4,08	1,13	0,91
D9	14.7.2017 8:28:31	1275,5	26,6	0,021	4,15	1,13	0,91